

**PERAMALAN JUMLAH PENUMPANG *AIRLINES*
PT. ANGKASA PURA II BANDARA SULTAN SYARIF KASIM II
PEKANBARU DENGAN ARIMA(0,1,1)(0,1,1)¹²**

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat
untuk Memperoleh Gelar Sarjana Sains
pada Jurusan Matematika

Oleh :

**IRMA ELIZA
10754000149**



**FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU
PEKANBARU
2011**

**PERAMALAN JUMLAH PENUMPANG *AIRLINES*
PT. ANGKASA PURA II BANDARA SULTAN SYARIF KASIM II
PEKANBARU DENGAN ARIMA(0,1,1)(0,1,1)¹²**

**IRMA ELIZA
10754000149**

Tanggal Sidang: 29 April 2011

Tanggal Wisuda: Juli 2011

Jurusan Matematika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Sultan Syarif Kasim Riau
Jl. HR. Soebrantas No.155 Pekanbaru

ABSTRAK

Tugas akhir ini menjelaskan tentang model peramalan jumlah penumpang *airlines* PT. Angkasa Pura II Pekanbaru. Tujuan studi ini yaitu untuk membentuk model peramalan jumlah penumpang *airlines* pada dua kasus yaitu jumlah penumpang yang datang dan berangkat menggunakan metode Box-Jenkins. Data *training* dan *testing* diambil dari bulan Januari 2005 sampai bulan Februari 2010 dan dari bulan Maret 2010 sampai Desember 2010. Hasil yang diperoleh menunjukkan bahwa model ARIMA(0,1,1)(0,1,1)¹² adalah model yang sesuai untuk peramalan jumlah penumpang *airlines* yang datang dan berangkat. Hasil peramalan mengindikasikan bahwa pola data jumlah penumpang *airlines* yang datang dan berangkat Tahun 2011 mengikuti pola data aktual tahun-tahun sebelumnya.

Kata kunci: *Airlines, ARIMA musiman, Box Jenkins*

DAFTAR ISI

	Halaman
LEMBAR PERSETUJUAN.....	ii
LEMBAR PENGESAHAN	iii
LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL.....	iv
LEMBAR PERNYATAAN	v
LEMBAR PERSEMBAHAN	vi
ABSTRAK	vii
<i>ABSTRACT</i>	viii
KATA PENGANTAR	ix
DAFTAR ISI.....	xi
DAFTAR SIMBOL.....	xiii
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvi
BAB I PENDAHULUAN	
1.1 Latar Belakang Masalah.....	I-1
1.2 Rumusan Masalah	I-2
1.3 Batasan Masalah	I-2
1.4 Tujuan Penelitian	I-3
1.5 Manfaat Penelitian	I-3
1.6 Sistematika Penulisan	I-4
BAB II LANDASAN TEORI	
2.1 Kebandarudaraan.....	II-1
2.2 Pentingnya Peramalan dalam Penerbangan	II-2
2.3 Peramalan	II-2
2.4 Metode Runtun Waktu (<i>Time Series</i>).....	II-5
2.5 Stasioneritas dan Model-Model yang Stasioner.....	II-6
2.6 Model Runtun Waktu yang Non Stasioner	II-10

2.7	Model ARIMA Musiman $(p,d,q)(P,D,Q)^s$	II-12
2.8	Tahap-Tahap Metode Box Jenkins.....	II-14
2.9	Penelitian-Penelitian Terkait Model Peramalan Jumlah Penumpang <i>Airlines</i>	II- 20
 BAB III METODOLOGI PENELITIAN		
3.1	Jenis dan Sumber Data	III-1
3.2	Metode Analisa Data	III-1
 BAB IV PEMBAHASAN		
4.1	Deskriptif Jumlah Penumpang <i>Airlines</i> PT. Angkasa Pura II Pekanbaru	IV-1
4.2	Pembentukan Model Peramalan Jumlah Penumpang <i>Airlines</i> yang Datang.....	IV-2
4.3	Pembentukan Model peramalan Jumlah Penumpang <i>Airlines</i> yang Berangkat.....	IV-14
 BAB V PENUTUP		
5.1	Kesimpulan	V-1
5.2	Saran.....	V-2
 DAFTAR PUSTAKA		
LAMPIRAN		
DAFTAR RIWAYAT HIDUP		

BAB I

PENDAHULUAN

Bab I dalam penelitian ini terdiri dari latar belakang masalah, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian dan sistematika penulisan.

1.1 Latar Belakang Masalah

Upaya perbaikan sarana dan prasarana yang selalu dilakukan oleh pihak Bandara Sultan Syarif Kasim II Pekanbaru disebabkan oleh peningkatan jumlah penumpang *airlines* dari waktu ke waktu. Jumlah penumpang *airlines* PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru meningkat setiap tahun. Bagian Umum dan Kepegawaian PT. Angkasa Pura II Pekanbaru, Ibu Ani (2011) mengatakan bahwa peningkatan ini disebabkan oleh semakin meningkatnya minat masyarakat dalam menggunakan jasa transportasi udara.

Adanya minat masyarakat yang semakin meningkat dalam menggunakan transportasi udara, mengakibatkan banyaknya berdiri perusahaan penerbangan baru dengan persaingan tarif yang semakin kompetitif. Persaingan tersebut memberikan kenyataan bahwa penerbangan tidak selalu membawa penumpang dalam jumlah yang sama tiap bulannya dalam setiap penerbangannya. Penerbangan kadang mengalami lonjakan penumpang atau sebaliknya mengalami penurunan. Adanya perubahan-perubahan tersebut dapat diambil sebagai data untuk keperluan dalam mengambil kebijakan, khususnya dibidang penerbangan untuk penyesuaian terhadap peningkatan dan penurunan penumpang di masa yang akan datang (Tarigan, 2009).

Peningkatan jumlah penumpang *airlines* yang terus terjadi ini menyebabkan peramalan jumlah penumpang *airlines* di Pekanbaru perlu dilakukan. *Manager* Bandara Sultan Syarif Kasim II Pekanbaru, Ibnu Hasan (2010) kepada Kompas mengatakan bahwa peningkatan jumlah penumpang *airlines* ini disebabkan oleh

setiap perusahaan penerbangan bersaing memberikan pelayanan yang terbaik, salah satunya harga tiket yang semakin kompetitif. Wawancara yang dilakukan terhadap Bagian Umum dan Kepegawaian PT. Angkasa Pura II Pekanbaru Ibu Ani (2011) menyebutkan bahwa jumlah penumpang *airlines* menurun pada awal tahun dan meningkat pada akhir tahun. Hal ini disebabkan oleh banyaknya masyarakat yang memanfaatkan liburan natal dan akhir tahun untuk bepergian ke luar kota.

Penelitian yang terkait peramalan jumlah penumpang *airlines* pernah dilakukan oleh peneliti sebelumnya diantaranya oleh Astin Nurhayati pada Tahun 2009 dan Peronika S. Tarigan pada Tahun 2009. Astin Nurhayati meramalkan jumlah penumpang *airlines* PT. Angkasa Pura I (Persero) Bandara Internasional Adi Sutjipto Yogyakarta. Peronika S. Tarigan Tahun 2009 meramalkan jumlah penumpang *airlines* PT. Angkasa Pura II (Persero) Bandara Polonia Medan. Berdasarkan beberapa hal tersebut, maka penulis tertarik mengambil judul **”Peramalan Jumlah Penumpang Airlines PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru dengan Metode Box Jenkins”**.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka dalam penelitian ini penulis mengangkat permasalahan yang akan diselesaikan yaitu:

- a. Bagaimana model peramalan jumlah penumpang *airlines* di PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru dengan mengaplikasikan metode Box Jenkins?
- b. Bagaimana hasil peramalan jumlah penumpang *airlines* pada Tahun 2011 dengan menggunakan model peramalan terbaik?

1.3 Batasan Masalah

Untuk mencegah meluasnya permasalahan yang ada dan agar lebih terarah, maka dilakukan pembatasan, yaitu:

- a. Data yang digunakan yaitu data jumlah penumpang *airlines* (datang dan berangkat) PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru perbulan selama 6 tahun (Januari 2005 sampai Desember 2010).
- b. Metode yang digunakan dalam penelitian ini adalah metode Box Jenkins yang *univariate*.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah:

- a. Mendapatkan model runtun waktu yang sesuai untuk memodelkan jumlah penumpang *airlines* PT. Angkasa Pura II bandara Sultan Syarif Kasim II Pekanbaru.
- b. Mendapatkan hasil peramalan jumlah penumpang *airlines* PT. Angkasa Pura II bandara Sultan Syarif Kasim II Pekanbaru Tahun 2011 dengan menggunakan model peramalan terbaik.

1.5 Manfaat Penelitian

Adapun manfaat dalam penelitian ini adalah:

- a. Bagi Penulis
Mengaplikasikan metode Box Jenkins dalam kasus nyata yaitu untuk pemodelan jumlah penumpang *airlines* PT. Angkasa Pura II bandara Sultan Syarif Kasim II Pekanbaru.
- b. Bagi Lembaga Pendidikan
Sebagai sarana informasi bagi pembaca dan sebagai bahan referensi bagi pihak yang membutuhkan.
- c. Bagi PT. Angkasa Pura II bandara Sultan Syarif Kasim II Pekanbaru.
Memberikan tambahan informasi mengenai model peramalan yang sesuai untuk peramalan penumpang *airlines* bandara Sultan Syarif Kasim II dan memberikan informasi nilai ramalannya Tahun 2011 sehingga memudahkan

dalam menentukan kebijakan, proses pengambilan keputusan dan membuat rencana perusahaan.

1.6 Sistematika Penulisan

Sistematika dalam pembuatan tulisan ini mencakup lima bab yaitu:

BAB I Pendahuluan

Bab ini berisi latar belakang masalah, rumusan masalah, tujuan penelitian, manfaat penelitian dan sistematika penulisan.

BAB II Landasan Teori

Bab ini menjelaskan teori-teori jumlah penumpang penerbangan, *airlines*, penelitian-penelitian terkait, model-model runtun waktu yang linier stasioner dan non stasioner, model ARIMA musiman $(p,d,q)(P,D,Q)^s$, *differencing* dan tahap-tahap dalam metode Box Jenkins.

BAB III Metodologi Penelitian

Bab ini berisikan langkah-langkah atau prosedur untuk memodelkan jumlah penumpang *airlines* PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru dengan menggunakan metode Box Jenkins.

BAB IV Pembahasan

Bab ini membahas tentang hasil-hasil yang diperoleh pada pemodelan jumlah penumpang *airlines* PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru (penumpang datang dan berangkat) dengan metode Box Jenkins.

BAB V Penutup

Bab ini berisikan kesimpulan dari hasil dan pembahasan yang telah dilakukan pada bab IV dan saran.

BAB II

LANDASAN TEORI

Bab II dalam penelitian ini terdiri atas kebandarudaraan, teori peramalan, beberapa model *time series* linier yang stasioner dan nonstasioner, model ARIMA musiman, beberapa penelitian terkait peramalan jumlah penumpang *airlines* dan tahap-tahap dalam metode Box Jenkins.

2.1 Kebandarudaraan

a. Definisi Bandara

Bandara singkatan dari bandar udara. Bandara adalah daerah tertentu di daratan maupun di daerah perairan termasuk setiap bangunan, instansi dan perlengkapan yang diperuntukkan bagi seluruh atau sebagian keberangkatan dan kedatangan serta gerakan udara di permukaan bumi (W.J.S. Poerwadarminta, Kamus Umum Bahasa Indonesia, 1991).

b. Airlines atau Perusahaan Penerbangan

Menurut Damardjati (2001), *airlines* atau perusahaan penerbangan adalah perusahaan milik swasta atau pemerintah yang khusus menyelenggarakan pelayanan angkutan udara untuk penumpang umum baik yang berjadwal maupun yang tidak berjadwal. Penerbangan berjadwal menempuh rute penerbangan berdasarkan jadwal waktu, kota tujuan maupun kota-kota persinggahan yang tetap. Sedangkan penerbangan tidak berjadwal sebaliknya, dengan waktu, rute maupun kota-kota tujuan dan persinggahan bergantung kepada kebutuhan dan permintaan pihak penyewa.

c. Definisi Penumpang

Menurut kamus bahasa Indonesia Tahun 2002, penumpang berarti orang yang ikut/naik kendaraan tertentu, misalnya kereta api, bus dan sebagainya. Dengan

demikian penumpang *airlines* yaitu orang yang ikut/naik transportasi udara dalam hal ini pesawat dari suatu tempat ke tempat lain.

2.2 Pentingnya Peramalan dalam Penerbangan

Penerbangan tidak selalu membawa penumpang dalam jumlah yang sama dalam setiap penerbangannya. Penerbangan kadang mengalami lonjakan penumpang atau sebaliknya. Adanya lonjakan atau penurunan tersebut, maka diperlukan adanya peramalan jumlah penumpang *airlines* untuk masa yang akan datang. Hal ini diperlukan untuk memudahkan perusahaan penerbangan dan pihak bandara dalam menentukan kebijakan, proses pengambilan keputusan, dan membuat rencana masa depan perusahaan (Tarigan, 2009). Melihat pentingnya peramalan dalam penerbangan, maka dalam tulisan ini akan diberikan teori-teori tentang peramalan.

2.3 Peramalan

Konsep peramalan sangat penting dalam berbagai bidang kehidupan, yaitu ketika suatu situasi masa depan harus diikutsertakan dalam proses pengambilan keputusan. Misalnya prediksi tentang kualitas udara, kualitas air, laju pengangguran, laju inflasi, dan beberapa hal yang berkaitan dengan penentuan kebijakan pemerintah. Contoh lain misalnya suatu perusahaan kereta api akan memerlukan peramalan jumlah penumpang pada hari-hari tertentu sebagai pertimbangan manajemen dalam menambah rangkaian gerbong (Prasetyo, 2006).

Peramalan adalah proses memperkirakan sesuatu yang akan terjadi di masa yang akan datang. Langkah dalam metode peramalan secara umum adalah pengumpulan data, menyeleksi data dan memilih data, memilih model peramalan, menerapkan model untuk peramalan, evaluasi hasil akhir (Subagyo, 1986; Fatmawati, 2007).

a. Jenis-Jenis Peramalan

Peramalan dapat dibedakan atas beberapa segi tergantung dari cara pendekatannya. Jenis-jenis peramalan ini antara lain (Santoso, 2009):

1. Peramalan jangka pendek, yaitu peramalan yang jangka waktunya mulai dari satu hari sampai satu musim.
2. Peramalan jangka menengah, yaitu peramalan yang jangka waktunya mulai dari satu musim sampai dua tahun.
3. Peramalan jangka panjang, yaitu peramalan yang jangka waktunya lebih dari dua tahun.

b. Metode Peramalan

Metode peramalan dapat dikelompokkan menjadi dua metode yaitu metode kualitatif dan kuantitatif. Namun dalam penelitian ini hanya menggunakan metode kuantitatif. Peramalan kuantitatif dapat diterapkan apabila memenuhi tiga kondisi sebagai berikut (Makridakis, 1992; Efendi, 2010):

1. Tersedia informasi tentang masa lalu
2. Informasi tersebut dapat dikuantitatifkan dalam bentuk data numerik.
3. Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut di masa mendatang.

Secara umum, metode peramalan kuantitatif dapat dibagi menjadi dua bagian, yaitu (Santoso, 2009):

1. Metode kausal (regresi)

Metode kausal yaitu memasukkan dan menguji variabel-variabel yang diduga mempengaruhi variabel *dependent*. Peramalan didasarkan atas hubungan sebab akibat (kausal), dengan demikian model akan lebih dari satu variabel.

2. Metode runtun waktu

Metode runtun waktu berusaha untuk meramalkan masa depan dengan menggunakan data historis, dengan kata lain metode runtun waktu mencoba melihat apa yang terjadi pada suatu kurun waktu tertentu dan menggunakan

data runtun waktu masa lalu untuk meramalkan. Metode ini didasarkan pada input data yang berupa data dengan basis waktu (harian, mingguan, bulanan dan lainnya).

c. Manfaat Peramalan

Manfaat peramalan dalam suatu penelitian yaitu melakukan analisa terhadap situasi yang akan diteliti untuk memperkirakan situasi yang akan terjadi dari sesuatu yang diteliti di masa depan. Peramalan merupakan suatu alat bantu dalam perencanaan yang efektif dan efesien. Dalam hal ini penyusunan suatu rencana untuk mencapai tujuan atau sasaran suatu organisasi terdapat perbedaan waktu antara kegiatan apa saja yang perlu dilakukan, kapan waktu pelaksanaan dan oleh siapa dilaksanakan. Perencanaan dan peramalan sangat erat kaitannya, ini dapat dilihat dalam hal penyusunan rencana, dimana dalam penyusunan melibatkan masalah peramalan (Lumbantobing, 2008).

Peramalan merupakan dasar untuk menyusun rencana karena akan membantu dalam mengadakan analisis terhadap data dari masa lalu. Sehingga dengan metode peramalan akan memberikan cara pemikiran, pengerjaan yang teratur dan terarah serta perencanaan yang sistematis hingga memberikan ketepatan hasil analisis (Lumbantobing, 2008).

Berdasarkan uraian di atas, dapat disimpulkan bahwa manfaat dari peramalan antara lain adalah sebagai berikut:

1. Membantu agar perencanaan suatu pekerjaan dapat diperkirakan dengan tepat.
2. Merupakan suatu pedoman dalam menentukan tingkat persediaan perencanaan dapat bekerja secara optimal.
3. Sebagai masukan untuk penentuan jumlah investasi.
4. Membantu menentukan pengembangan suatu pekerjaan untuk periode selanjutnya.

d. Hubungan Peramalan dengan Rencana

Peramalan adalah sesuatu yang akan terjadi pada waktu yang akan datang, sedangkan rencana merupakan penentuan apa yang akan dilakukan pada waktu yang akan datang. Misalnya para orang tua murid mulai menabung untuk persiapan kuliah anaknya. Mahalnya biaya pendidikan di perguruan tinggi merupakan ramalan sedangkan orang tua mulai menabung merupakan rencana. Jadi rencana adalah suatu penentuan terlebih dahulu tentang kegiatan yang akan dilakukan di waktu yang akan datang. Berdasarkan hasil suatu ramalan, dapat dibuat beberapa rencana yang memberikan keuntungan (Munandar, 1985; Widodo, 2005).

2.4 Metode Runtun Waktu (*Time Series Methode*)

Ada beberapa metode analisis yang dapat digunakan untuk kegiatan peramalan, salah satunya yaitu menggunakan metode runtun waktu.

a. Pengertian Runtun Waktu (*Time Series*)

Data runtun waktu adalah data yang dikumpulkan berdasarkan rentang waktu tertentu. Data runtun waktu dapat dipisahkan berdasarkan empat unsur yaitu tren, musiman, siklus serta komponen acak (Firdaus, 2006).

Berdasarkan sejarah nilai observasinya, runtun waktu dibedakan menjadi dua yaitu runtun waktu deterministik dan runtun waktu stokastik. Runtun waktu deterministik adalah runtun waktu yang nilai observasinya yang akan datang dapat diramalkan secara pasti berdasarkan observasi lampau. Sedangkan runtun waktu stokastik adalah runtun waktu dengan nilai observasi yang akan datang bersifat probabilistik, berdasarkan observasi yang lampau (Zanzawi, 1987; Jumroh, 2005).

b. Bentuk-bentuk data Runtun Waktu

Beberapa pola yang mungkin terjadi ketika suatu data akan dianalisa adalah (Prasetyo, 2009):

- a. Pola data stasioner dari waktu ke waktu
- b. Pola tren (*trend*) baik turun maupun naik
- c. Pola musiman (*Seasonal*)
- d. Pola tren dan musiman (*trend and seasonal*)

2.5 Stasioneritas dan Model-Model yang Stasioner

Stasioneritas berarti tidak terdapat pertumbuhan atau penurunan pada data. Data secara kasarnya harus horizontal sepanjang sumbu waktu. Artinya fluktuasi data berada di sekitar nilai rata-rata yang konstan, tidak bergantung pada waktu. Secara singkatnya data dikatakan stasioner jika data mempunyai rata-rata dan varians konstan untuk setiap periode pengamatan (Firdaus, 2006). Selanjutnya, akan dijelaskan model-model runtun waktu yang stasioner, yaitu (Hanke, 2009):

1. Model *Autoregressive* atau **AR(p)**

AR(*p*) adalah model linier yang paling dasar untuk proses yang stasioner, model ini dapat diartikan sebagai proses hasil regresi dengan dirinya sendiri, artinya model ini menggambarkan bahwa variabel *dependent* dipengaruhi oleh variabel *dependent* itu sendiri. Secara umum model AR mempunyai bentuk matematis:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \cdots + \phi_p Y_{t-p} + a_t, \quad (2.1)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-i} adalah data pada periode $t - i, i = 1, 2, \dots, p$

a_t adalah *error* pada periode t

ϕ_0 adalah suatu konstanta

ϕ_i adalah parameter *Autoregressive* ke- $i, i = 1, 2, \dots, p$

Bentuk umum model AR(*p*) pada persamaan (2.1) dapat juga ditulis dalam bentuk (Delurgio):

$$\phi(B)Y_t = \phi_0 + a_t, \quad (2.2)$$

dengan $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ dan $B^i Y_t = Y_{t-i}, i = 1, 2, \dots, p$

a. Model Autoregresi(Autoregressive) Tingkat 1 (AR(1))

Model autoregresi tingkat 1 atau AR(1), secara matematis didefinisikan

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + a_t, \quad (2.3)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-1} adalah data pada periode $t - 1$

a_t adalah *error* pada periode t

ϕ_0 adalah suatu konstanta

ϕ_1 adalah parameter AR ke-1

b. Model Autoregresi (Autoregressive) Tingkat 2 (AR(2))

Model autoregresif tingkat 2 atau AR(2) didefinisi secara matematis sebagai:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + a_t, \quad (2.4)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-i} adalah data pada periode $t-i, i = 1, 2$

a_t adalah *error* pada periode t

ϕ_0 adalah suatu konstanta

ϕ_1 adalah parameter AR ke-1

ϕ_2 adalah parameter AR ke-2

Model AR(3) dan seterusnya hingga AR(p), dapat dilanjutkan dengan mengikuti pola umum AR(p) pada persamaan (2.1).

2. Model *Moving Average* atau MA(q)

Bentuk umum dari *moving average* tingkat q atau MA(q) didefinisikan sebagai:

$$Y_t = \theta_0 + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (2.5)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

a_t adalah *error* pada periode t

a_{t-i} adalah *error* pada periode $t - i, i = 1, 2, \dots, q$

θ_0 adalah suatu konstanta

θ_i adalah parameter *moving average* ke- $i, i = 1, 2, \dots, q$

Bentuk umum model MA(q) pada Persamaan (2.5) dapat juga ditulis dalam bentuk:

$$Y_t = \theta_0 + \theta(B)a_t, \quad (2.6)$$

dengan $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ dan $B^i a_t = a_{t-i}, i = 1, 2, \dots, q$

a. Model *Moving Average* Tingkat 1 atau MA(1)

Sama seperti model AR, *moving average* juga diawali dengan tingkat 1 atau MA(1), didefinisikan sebagai:

$$Y_t = \theta_0 + a_t - \theta_1 a_{t-1}, \quad (2.7)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

a_t adalah *error* pada periode t

a_{t-1} adalah *error* pada periode $t - 1$

θ_0 adalah suatu konstanta

θ_1 adalah parameter MA ke-1

b. Model *Moving Average* Tingkat 2 atau MA(2)

Model *moving average* tingkat 2 atau MA(2), didefinisikan sebagai:

$$Y_t = \theta_0 + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}, \quad (2.8)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

a_t adalah *error* pada periode t

a_{t-i} adalah *error* pada periode $t-i, i = 1, 2$

θ_0 adalah suatu konstanta

θ_i adalah parameter MA ke $i, i = 1, 2$

Model MA(3) dan seterusnya hingga MA(q), sama seperti model AR dapat dilanjutkan dengan mengikuti pola umum MA(q) pada Persamaan (2.5).

3. Model Campuran atau *Autoregressive Moving Average* ARMA(p, q)

Model ini merupakan gabungan antara AR(p) dengan MA(q), sehingga dinyatakan sebagai ARMA(p, q), dengan bentuk umumnya:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (2.9)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-i} adalah data pada periode $t-i, i = 1, 2, \dots, p$

a_t adalah *error* pada periode t

a_{t-i} adalah *error* pada periode $t-i, i = 1, 2, \dots, q$

ϕ_0 adalah suatu konstanta

ϕ_i adalah parameter *Autoregressive* ke- $i, i = 1, 2, \dots, p$

θ_i adalah parameter *Moving Average* ke- $i, i = 1, 2, \dots, q$

Bentuk umum model ARMA(p, q) pada Persamaan (2.9) dapat juga ditulis dalam bentuk:

$$\phi(B)Y_t = \phi_0 + \theta(B)a_t, \quad (2.10)$$

dengan $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$

dan $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$

a. Model ARMA(1,1)

Model ini merupakan kombinasi antara AR(1) dan MA(1), matematisnya dapat didefinisikan sebagai:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + a_t - \theta_1 a_{t-1}, \quad (2.11)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-1} adalah data pada periode $t - 1$

a_t adalah *error* pada periode t

a_{t-1} adalah *error* pada periode $t - 1$

ϕ_0 adalah suatu konstanta

ϕ_1 adalah koefisien AR ke-1

θ_1 adalah koefisien MA ke-1

Model ARMA dapat dilanjutkan dengan mengikuti pola umum ARMA(p, q) pada Persamaan (2.9), misalnya untuk model ARMA(1,2), ARMA(2,1) dan seterusnya hingga ARMA(p, q).

2.6 Model Runtun Waktu Non Stasioner

Apabila nonstasioneritas ditambahkan pada proses campuran ARMA maka modelnya ARIMA(p, d, q), sehingga model ini merupakan model yang nonstasioner.

Secara matematis didefinisikan (Efendi, 2010):

$$Y_t = \phi_0 + (1 + \phi_1)Y_{t-1} + (\phi_2 - \phi_1)Y_{t-2} + \dots + (\phi_p - \phi_{p-1})Y_{t-p} - \phi_p Y_{t-p-1} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (2.12)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-i} adalah data pada periode $t - i, i = 1, 2, \dots, p$

a_t adalah *error* pada periode t

a_{t-i} adalah *error* pada periode $t - i, i = 1, 2, \dots, q$

ϕ_0 adalah suatu konstanta

ϕ_i adalah parameter *Autoregressive* ke- $i, i = 1, 2, \dots, p$

θ_i adalah parameter *Moving Average* ke- $i, i = 1, 2, \dots, q$

Bentuk umum model ARIMA(p, d, q) pada Persamaan (2.12) diperoleh dari penurunan bentuk:

$$\phi(B)(1 - B)^d Y_t = \phi_0 + \theta(B)a_t, \quad (2.13)$$

dengan

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p, (1 - B)^d = \text{differencing tingkat } d$$

$$\text{dan } \theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

a. Model Autoregressive Integrated Moving Average (1,1,0)

Model ini ditulis dalam bentuk matematis sebagai:

$$Y_t = \phi_0 + (1 + \phi_1)Y_{t-1} - \phi_1 Y_{t-2} + a_t, \quad (2.14)$$

dengan:

Y_t adalah data pada periode $t, i = 1, 2, \dots, n$

Y_{t-1} adalah data pada periode $t - 1$

a_t adalah *error* pada periode t

ϕ_0 adalah suatu konstanta

ϕ_1 adalah parameter *Autoregressive* tingkat 1

b. Model Autoregressive Integrated Moving Average (0,1,1)

Model ini ditulis dalam bentuk matematis sebagai:

$$Y_t = \theta_0 + Y_{t-1} + a_t - \theta_1 a_{t-1}, \quad (2.15)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Y_{t-1} adalah data pada periode $t - 1$
 a_t adalah *error* pada periode t
 a_{t-1} adalah *error* pada periode $t - 1$
 θ_0 adalah suatu konstanta
 θ_1 adalah parameter *Moving Average* tingkat 1

c. Model Autoregressive Integrated Moving Average (1,1,1)

Model ini ditulis dalam bentuk matematis sebagai:

$$Y_t = \phi_0 + (1 + \phi_1)Y_{t-1} - \phi_1 Y_{t-2} + a_t - \theta_1 a_{t-1}, \quad (2.16)$$

dengan:

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$
 Y_{t-1} adalah data pada periode $t - 1$
 a_t adalah *error* pada periode t
 a_{t-1} adalah *error* pada periode $t - 1$
 ϕ_0 adalah suatu konstanta
 ϕ_1 adalah parameter *Autoregressive* tingkat 1
 θ_1 adalah parameter *Moving Average* tingkat 1

Model *Autoregressive Integrated Moving Average* tingkat selanjutnya mengikuti pola umum model $ARIMA(p, d, q)$ pada Persamaan (2.13).

2.7 Model $ARIMA(p, d, q)(P, D, Q)^s$

Model ini merupakan model untuk data yang mengandung unsur musiman (*seasonal*). Model ini disebut juga dengan model *ARIMA Box Jenkins Musiman* atau $ARIMA(p, d, q)(P, D, Q)^s$, yang mempunyai bentuk umum (Wei, 1989):

$$\phi_p(B)\Phi_P(B)^s(1-B)^d(1-B^s)^D Y_t = \theta_0 + \theta_q(B)\Theta_Q(B)^s a_t, \quad (2.17)$$

dengan:

p, d, q adalah tingkat AR, *differencing* dan MA non musiman

P, D, Q adalah tingkat AR, *differencing* dan MA musiman

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\Phi_P(B)^S = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}$$

$(1 - B)^d$ adalah tingkat *differencing* non musiman

$(1 - B^S)^D$ adalah tingkat *differencing* musiman

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

$$\Theta_Q(B)^S = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}$$

a_t adalah *error* pada periode t

θ_0 adalah suatu konstanta

B adalah operator mundur

Y_t adalah data pada periode $t, t = 1, 2, \dots, n$

Contoh 2.1

Model ARIMA(0,1,1)(0,1,1)¹²

Model ini merupakan kombinasi antara model MA(1) non musiman sekali *differencing* dengan model MA(1) musiman sekali *differencing*, dengan model matematisnya sebagai berikut:

$$(1 - B)^1(1 - B^{12})^1 Y_t = \theta_0 + \theta_1(B)\Theta_1(B)^{12} a_t, \quad (2.18)$$

dengan

$$(1 - B)Y_t = Y_t - Y_{t-1}$$

$$(1 - B^{12})Y_t = Y_t - Y_{t-12}$$

$$\theta_1(B) = 1 - \theta_1 B$$

$$\Theta_1(B)^{12} = 1 - \Theta_1 B^{12}$$

Maka penurunan model ARIMA(0,1,1)(0,1,1)¹² secara matematis adalah:

$$(1 - B)(1 - B^{12})Y_t = \theta_0 + \theta_1(B)\Theta_1(B)^{12} a_t$$

$$(1 - B)(1 - B^{12})Y_t = \theta_0 + (1 - \theta_1 B)(1 - \Theta_1 B^{12})a_t$$

$$(1 - B - B^{12} + B^{13})Y_t = \theta_0 + (1 - \theta_1 B - \Theta_1 B^{12} + \theta_1 \Theta_1 B^{13})a_t$$

$$Y_t - BY_t - B^{12}Y_t + B^{13}Y_t = \theta_0 + a_t - \theta_1 B a_t - \Theta_1 B^{12} a_t + \theta_1 \Theta_1 B^{13} a_t$$

$$Y_t - Y_{t-1} - Y_{t-12} + Y_{t-13} = \theta_0 + a_t - \theta_1 a_{t-1} - \Theta_1 a_{t-12} + \theta_1 \Theta_1 a_{t-13}$$

diperoleh:

$$Y_t = \theta_0 + Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - \theta_1 a_{t-1} - \Theta_1 a_{t-12} + \theta_1 \Theta_1 a_{t-13} \quad (2.19)$$

Model ARIMA musiman $(p,d,q)(P,D,Q)^s$ selanjutnya dapat diperoleh dengan mengikuti bentuk umum model musiman multiplikatif pada Persamaan (2.17).

2.8 Tahap-Tahap dalam Metode Box-Jenkins

Tahap-tahap dalam metode Box Jenkins secara lengkap adalah sebagai berikut (Box Jenkins, 1970; Delurgio, 1998):

1. Identifikasi model
2. Estimasi parameter dalam model
3. Verifikasi model (Diagnostik *check*)
4. Menggunakan model untuk peramalan

1. Identifikasi model

Identifikasi model dilakukan dengan melihat grafik autokorelasi dan autokorelasi parsial data yang stasioner. Data stasioner adalah data yang mempunyai rata-rata dan varians yang konstan sepanjang waktu. Apabila data tidak stasioner, perlu dimodifikasi untuk menghasilkan data yang stasioner. Salah satu metode yang umum dipakai adalah metode pembedaan (*differencing*) (Soejoeti, 1987; Fatmawati, 2007). *Differencing* yaitu selisih antara data tertentu dengan data sebelumnya.

a. *Differencing* non musiman

Jika *differencing* non musiman berorder satu, maka secara matematis ditulis dalam bentuk (Santoso, 2009):

$$\Delta Y_t = Y_t - Y_{t-1}, \quad (2.20)$$

Kasus yang banyak terjadi yaitu *differencing* orde satu masih belum menghasilkan data yang stasioner, dapat dilakukan *differencing* orde dua.

Differencing orde dua adalah *differencing* orde pertama dari hasil *differencing* orde pertama untuk runtun waktu asli, jadi jika $\Delta^2 Y_t$ adalah *differencing* orde dua dari Y_t , dan ΔY_t adalah *differencing* orde pertama dari Y_t , maka

$$\begin{aligned}\Delta^2 Y_t &= \Delta Y_t - \Delta Y_{t-1} \\ \Delta^2 Y_t &= (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \\ \Delta^2 Y_t &= Y_t - 2Y_{t-1} + Y_{t-2}\end{aligned}\tag{2.21}$$

b. *Differencing* musiman

Konsep *differencing* musiman sama dengan *differencing* non musiman, yang membedakan hanya pada periode data sebelumnya. Jika *differencing* musiman berorde satu, maka secara matematis ditulis dalam bentuk (Cryer, 1986):

$$\nabla_s Y_t = Y_t - Y_{t-s}, \tag{2.22}$$

dengan S adalah periode musiman.

Jika dalam *differencing* musiman orde satu belum memberikan data yang stasioner, maka dilakukan *differencing* musiman orde dua, yang secara matematis ditulis:

$$\begin{aligned}\nabla_s^2 Y_t &= \nabla_s Y_t - \nabla_s Y_{t-s} \\ \nabla_s^2 Y_t &= (Y_t - Y_{t-s}) - (Y_{t-s} - Y_{t-s-s}) \\ \nabla_s^2 Y_t &= Y_t - 2Y_{t-s} + Y_{t-2s}\end{aligned}\tag{2.23}$$

Identifikasi pada model $AR(p)$ yaitu grafik ACF digunakan untuk menentukan kestasioneran data runtun waktu yang digunakan, yaitu dengan melihat *lag-lag*nya yang turun secara eksponensial atau sinusoidal. Pembuatan grafik PACF digunakan untuk menentukan kelas model dari data runtun waktu yang digunakan, yaitu dengan melihat fungsi *cut off* setelah *lag p*. Sedangkan pada model $MA(q)$ grafik PACF digunakan untuk menentukan kestasioneran data runtun waktu yang digunakan, yaitu dengan melihat *lag-lag*nya yang turun secara eksponensial atau sinusoidal. Kemudian grafik ACF digunakan untuk menentukan kelas model dari data

runtun waktu yang digunakan, yaitu dengan melihat fungsi *cut off* setelah lag q (Efendi, 2010).

Identifikasi model untuk data yang mengandung unsur tren musiman, juga dilakukan dengan melihat pasangan ACF dan PACF. Periode musiman pada kasus data tren musiman diperoleh dengan melihat grafik ACF hasil *differencing* non musiman yaitu lag yang mempunyai nilai korelasi yang tertinggi (Cryer, 1986).

2. Estimasi parameter dalam model

Setelah model diidentifikasi, tahap selanjutnya yaitu mencari estimasi terbaik untuk parameter-parameter dalam model tersebut. Estimasi parameter dilakukan dengan menggunakan metode kuadrat terkecil (*ordinary least squares*). Metode *least squares* merupakan suatu metode yang digunakan untuk mengestimasi parameter dengan cara meminimumkan jumlah kuadrat *error*. Jumlah kuadrat *error* untuk persamaan runtun waktu tingkat satu analog dengan persamaan kuadrat *error* regresi linier sederhana, yaitu (Sembiring, 1995):

$$J = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (2.24)$$

untuk persamaan regresi sederhana:

$$\hat{y}_i = \alpha + \beta x_i, i = 1, 2, \dots, n \quad (2.25)$$

Namun pada runtun waktu misalnya untuk model MA(1) berarti menggantikan y_i dengan Y_t , x_i dengan a_{t-1} , e_i dengan a_t , α dengan θ_0 dan β dengan θ_1 , maka persamaan 2.24 menjadi:

$$J = \sum_{t=1}^n a_t^2 = \sum_{t=1}^n (Y_t - \hat{Y}_t)^2, \quad (2.26)$$

untuk model:

$$\hat{Y}_t = \theta_0 - \theta_1 a_{t-1}, \quad (2.27)$$

dengan mensubstitusikan persamaan 2.27 ke persamaan 2.26, maka jumlah kuadrat *error* menjadi:

$$J = \sum_{t=1}^n a_t^2 = \sum_{t=1}^n (Y_t - \theta_0 + \theta_1 a_{t-1})^2, \quad (2.28)$$

meminimumkan kuadrat error berarti meminimumkan persamaan 2.28 dengan cara menurunkan terhadap θ_0 dan θ_1 dan menyamakan dengan nol.

$$\frac{\partial J}{\partial \theta_0} = 0 \quad (2.29)$$

$$\frac{\partial J}{\partial \theta_0} = \frac{\partial}{\partial \theta_0} \sum_{t=1}^n (Y_t - \theta_0 + \theta_1 a_{t-1})^2 = 0 \quad (2.30)$$

$$-2 \sum_{t=1}^n (Y_t - \theta_0 + \theta_1 a_{t-1}) = 0 \quad (2.31)$$

$$\theta_0 = \frac{\sum_{t=1}^n Y_t + \theta_1 \sum_{t=1}^n a_{t-1}}{n} \quad (2.32)$$

$$\theta_0 = \bar{Y}_t + \theta_1 \bar{a}_{t-1} \quad (2.33)$$

selanjutnya menurunkan persamaan 2.28 terhadap θ_1 , maka:

$$\frac{\partial J}{\partial \theta_1} = 0 \quad (2.34)$$

$$\frac{\partial J}{\partial \theta_1} = \frac{\partial}{\partial \theta_1} \sum_{t=1}^n (Y_t - \theta_0 + \theta_1 a_{t-1})^2 = 0 \quad (2.35)$$

$$2 \sum_{t=1}^n (Y_t - \theta_0 + \theta_1 a_{t-1})(a_{t-1}) = 0 \quad (2.36)$$

$$\theta_1 = \frac{\sum_{t=1}^n Y_t a_{t-1} - \left(\sum_{t=1}^n Y_t \right) \frac{\left(\sum_{t=1}^n a_{t-1} \right)}{n}}{\left(- \sum_{t=1}^n a_{t-1}^2 \right) + \frac{\left(\sum_{t=1}^n a_{t-1} \right)^2}{n}} \quad (2.37)$$

Setelah parameter diestimasi selanjutnya dilakukan uji signifikansi parameter tersebut dalam model dengan cara membandingkan nilai P value dengan level toleransi (α) dalam pengujian hipotesis:

H_0 : parameter tidak signifikan dalam model

H_1 : parameter signifikan dalam model

Kriteria penerimaan H_0 jika nilai P value $> \alpha$ dan penolakan H_0 jika nilai P value $< \alpha$.

3. Verifikasi model (diagnostik *check*)

Tahap diagnostik *check* yaitu melihat apakah model yang dihasilkan sudah layak digunakan untuk peramalan atau belum, dengan melihat residual yang dihasilkan model. Ada dua uji yang dilakukan yaitu uji independensi dan uji kenormalan residual.

a. Uji independensi residual

Uji ini dilakukan untuk mendeteksi independensi *residual* antar lag yang residual dapat dilakukan dengan melihat pasangan ACF dan PACF residual yang dihasilkan model. Selain dengan menggunakan ACF dan PACF residual, independensi residual dapat juga dilihat pada kerandoman residual. Kerandoman residual diketahui dengan membandingkan nilai P -value pada output proses *Ljung Box Pierce* dengan selang kepercayaan yang digunakan dalam uji hipotesis:

H_0 : Residual model mengikuti proses random

H_1 : Residual model tidak mengikuti proses random

Kriteria penerimaan H_0 yaitu jika P -value $>$ selang kepercayaan (Montgomery, 2008).

b. Uji kenormalan residual

Uji kenormalan residual dilakukan dengan melihat histogram residual yang dihasilkan model. Jika histogram residual telah mengikuti pola kurva normal, maka model telah memenuhi asumsi kenormalan sehingga layak digunakan untuk

peramalan. Selanjutnya, jika model yang dihasilkan lebih dari satu, untuk memilih model yang terbaik dilakukan uji *mean square error* (*MSE*) dengan rumus:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (2.38)$$

dengan:

Y_t adalah data pada periode t , $t = 1, 2, 3, \dots, n$

\hat{Y}_t adalah data ramalan periode t

n adalah jumlah data

Model yang dipilih yaitu model yang mempunyai nilai *MSE* yang terkecil.

4. Penerapan model untuk peramalan

Tahap terakhir dalam metode Box Jenkins yaitu menggunakan model terpilih untuk peramalan. Model terbaik yang diperoleh pada tahap verifikasi digunakan untuk melakukan peramalan yang meliputi data *training*, data *testing* dan peramalan. Pada tahap peramalan data *training*, data yang digunakan yaitu data aktual, sedangkan untuk peramalan pada data *testing*, data yang digunakan tidak ada unsur data aktual tetapi data hasil peramalan pada data *training*. Selanjutnya pada tahap peramalan, data yang digunakan yaitu data hasil peramalan pada data *testing*. Misalnya, model yang diperoleh adalah AR(1) maka tahap peramalan tersebut sebagai berikut:

a. *Training*

$$\hat{Y}_2 = \phi_0 + \phi_1 Y_1 \quad (2.39)$$

dan seterusnya hingga data terakhir pada data *training*.

b. *Testing*

$$\hat{Y}_t = \phi_0 + \phi_1 \hat{Y}_{t-1} \quad (2.40)$$

dengan \hat{Y}_{t-1} adalah data terakhir hasil peramalan pada data *training*.

c. Peramalan

Model matematis untuk tahap peramalan ini sama dengan model matematis data *testing* pada Persamaan (2.40), tetapi \hat{Y}_{t-1} adalah data terakhir hasil peramalan pada data *testing*.

2.9 Penelitian-Penelitian Terkait Model Peramalan Jumlah Penumpang Airlines.

Penelitian-penelitian terkait model peramalan jumlah penumpang *airlines* dan peramalan lain yang pernah dilakukan sebelumnya disajikan dalam Tabel 2.1:

Tabel 2.1 Penelitian terkait penumpang *airlines* dan runtun waktu yang sudah pernah dilakukan.

No	Judul Penelitian	Peneliti	Tahun	Metode
1	Aplikasi model ARIMA untuk forecasting produksi gula pada PT. Perkebunan Nusantara IX (Persero)	Istiqomah	2006	ARIMA
2	Peramalan Jumlah Penderita Demam Berdarah Menggunakan Model ARIMA Musiman	Ika Milasari	2008	ARIMA Musiman
3	Peramalan jumlah penumpang pada PT Angkasa Pura I (Persero) kantor cabang bandar udara internasional Adi Sutjipto Yogyakarta dengan metode <i>Winter's Exponential Smoothing</i> dan Seasonal ARIMA	Astin Nurhayati	2009	<i>Winter's Exponential Smoothing</i> dan Seasonal ARIMA
4	Proyeksi jumlah penumpang domestik pada PT. Angkasa Pura II bandara Polonia Medan 2010-2011	Peronika S Tarigan	2009	<i>Exponential Smoothing</i>
5	Metode Autoregresi dan Autokorelasi untuk maramalkan jumlah penjualan pakaian di toko Yuanita Purwodadi	Wahyu Widodo	2009	Autoregresi dan Autokorelasi
6	Prosedur pelaporan hasil penjualan kupon pelayanan penumpang pesawat udara (PJP2U) PT. Angkasa Pura I (Persero) di Bandar Udara Adi Soemarno Surakarta	Wira Mardaningsih	2010	

BAB III

METODOLOGI PENELITIAN

Bab III dalam penelitian ini menjelaskan tentang metode penelitian yang penulis gunakan yaitu studi lapangan dan studi pustaka. Metode studi lapangan yaitu metode pengumpulan data dengan cara pengambilan data jumlah penumpang *airlines* langsung ke PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru. Sedangkan metode studi pustaka (*literature*) yaitu penulis mengumpulkan, memilih dan menganalisis serta menelaah sumber pustaka dengan cara membaca buku-buku yang berkaitan dengan runtun waktu, kemudian melakukan analisis data dengan metode Box Jenkins.

3.1 Jenis dan Sumber Data

a. Jenis Data

Data yang digunakan dalam penelitian ini adalah data runtun waktu yaitu jumlah penumpang *airlines* yang berangkat dan yang datang perbulan selama 6 tahun mulai bulan Januari 2005 sampai bulan Desember 2010.

b. Sumber Data

Data dalam penelitian ini diperoleh dari PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru.

3.2 Metode Analisis Data

Metode analisis data yang digunakan dalam penelitian ini adalah dengan menggunakan metode runtun waktu (Box Jenkins). Selanjutnya pengolahan data dilakukan dengan bantuan *software* statistika yaitu minitab. Adapun tahap-tahap pembentukan model peramalan dengan menggunakan metode Box Jenkins adalah sebagai berikut:

Tahap 1. Identifikasi Model

Hal yang pertama yang dilakukan dalam melakukan peramalan menggunakan metode Box Jenkins adalah melihat data stasioner atau tidak. Apabila data tidak stasioner, maka perlu dimodifikasi untuk menghasilkan data yang stasioner dengan cara *differencing*. Tahap identifikasi model ini dilakukan dengan pembuatan plot data aktual, pembuatan grafik fungsi autokorelasi (ACF) dan pembuatan grafik fungsi autokorelasi parsial (PACF) dengan bantuan *software* minitab.

Tahap 2. Estimasi Parameter

Tahap ini yaitu menentukan parameter dalam model dengan menggunakan metode kuadrat terkecil (*ordinary least squares*).

Tahap 3. Verifikasi Model (pengujian diagnostik).

Pengujian diagnostik dilakukan untuk menguji kelayakan model peramalan, jika model yang diperoleh belum layak maka dicari model lain. Ada dua uji yang dilakukan dalam tahap diagnostik yaitu uji independensi dan kenormalan residual.

a. Uji independensi residual

Uji ini dilakukan dengan melihat pasangan ACF dan PACF residual yang dihasilkan model. Selain menggunakan ACF dan PACF residual, independensi dilakukan juga dengan melihat kerandoman residual yaitu dengan membandingkan nilai *P-value* pada output proses *Ljung Box Pierce* dengan selang kepercayaan yang digunakan dalam uji hipotesis.

b. Uji kenormalan residual

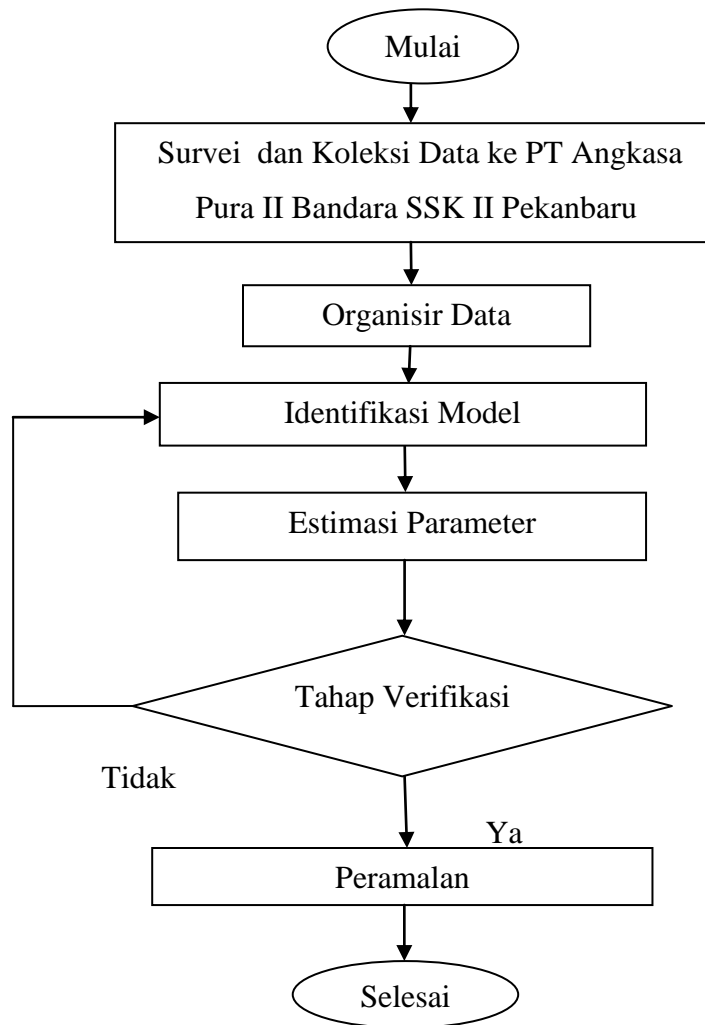
Uji ini dilakukan dengan melihat histogram residual yang dihasilkan model. Jika histogram residual telah mengikuti pola kurva normal, maka asumsi kenormalan telah dipenuhi.

Jika model yang didapatkan dua atau lebih dari satu, untuk memilih model yang paling sesuai dilakukan uji yaitu *mean squared error*.

Tahap 4. Penerapan model untuk peramalan

Setelah mendapatkan model peramalan terbaik, selanjutnya dilakukan peramalan. Tahap ini terdiri atas tiga bagian, yaitu untuk data *training*, *testing* dan peramalan.

Langkah-langkah pengumpulan data dan membentuk model peramalan diatas dapat digambarkan dalam *flow chart* sebagai berikut:



Gambar 3.1 *Flow chart* metode pengumpulan data dan pembentukan model


BAB IV

PEMBAHASAN

Bab IV dalam penelitian ini akan membahas tentang analisa dan peramalan jumlah penumpang *airlines* (datang dan berangkat) yang terdiri dari data dan pembentukan model peramalan. Pembentukan model peramalan secara umum terdiri dari 4 tahap yaitu tahap identifikasi model, estimasi parameter model, verifikasi model dan penerapan model untuk peramalan.

4.1 Deskriptif Jumlah Penumpang *Airlines* PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru

Jumlah penumpang *airlines* Bandara Sultan Syarif Kasim II Pekanbaru pada Tahun 2005 sampai 2010 mengalami kenaikan disetiap tahunnya. Untuk lebih jelasnya, jumlah penumpang *airlines* disajikan pada Lampiran A dan Gambar 4.1:



Gambar 4.1 Histogram jumlah penumpang *airlines*

Gambar 4.1 menunjukkan bahwa jumlah penumpang *airlines* yang datang dan berangkat meningkat setiap tahun. Jumlah penumpang yang datang tertinggi terjadi pada Tahun 2010 yaitu 1.132.444 orang dan terendah terjadi pada Tahun 2005 yaitu 728.790 orang. Sama halnya dengan jumlah penumpang yang datang, jumlah

penumpang yang berangkat tertinggi juga terjadi pada Tahun 2010 yaitu 1.117.270 orang dan terendah terjadi pada Tahun 2005 yaitu 738.485 orang.

Peningkatan jumlah penumpang *airlines* di Kota Pekanbaru ini terjadi disebabkan oleh semakin meningkatnya minat masyarakat dalam menggunakan transportasi udara. Peningkatan jumlah penumpang *airlines* setiap tahun ini juga disebabkan oleh banyaknya berdiri perusahaan penerbangan yang bersaing dalam memberikan pelayanan terbaik kepada para penumpang. Adanya pelayanan terbaik yang diberikan oleh perusahaan-perusahaan penerbangan ini semakin meningkatkan minat masyarakat dalam menggunakan transportasi udara dalam melakukan perjalanan.

Tabel 4.1 Statistik deskriptif jumlah penumpang *airlines*

Variabel	N (Jumlah Data)	Mean (orang)	Minimum (orang)	Maksimum (orang)
Datang	72	76.278	54.306	118.542
Berangkat	72	76.685	53.042	104.983

Berdasarkan Tabel 4.1 diketahui bahwa rata-rata perbulan jumlah penumpang *airlines* yang datang adalah 76.278 orang, tertinggi 118.542 orang pada bulan Desember 2010 dan terendah terjadi pada bulan Oktober 2005 yaitu sebesar 54.306 orang. Sedangkan rata-rata perbulan jumlah penumpang *airlines* yang berangkat adalah 76.685 orang, tertinggi 104.983 orang yang terjadi pada bulan Oktober 2010, sedangkan terendah terjadi pada bulan Oktober 2005 yaitu 53.042 orang.

Selanjutnya dilakukan tahap-tahap pembentukan model peramalan dengan menggunakan metode Box Jenkins yaitu identifikasi model, estimasi parameter dalam model, *diagnostics check*, dan penerapan model untuk peramalan.


4.2 Pembentukan Model Peramalan Jumlah Penumpang yang Datang

Bagian 4.2 ini menjelaskan tentang tahap-tahap pembentukan model peramalan jumlah penumpang yang datang dengan metode Box Jenkins. Data yang digunakan untuk pembentukan model tersebut sebanyak 72 data yaitu data bulanan

selama 6 tahun dari bulan Januari 2005 sampai Desember 2010. Data jumlah penumpang *airlines* yang datang disajikan pada Lampiran A dan Gambar 4.1. Adapun tahap-tahap pembentukan model yaitu identifikasi model, estimasi parameter, verifikasi model dan penerapan model untuk peramalan.

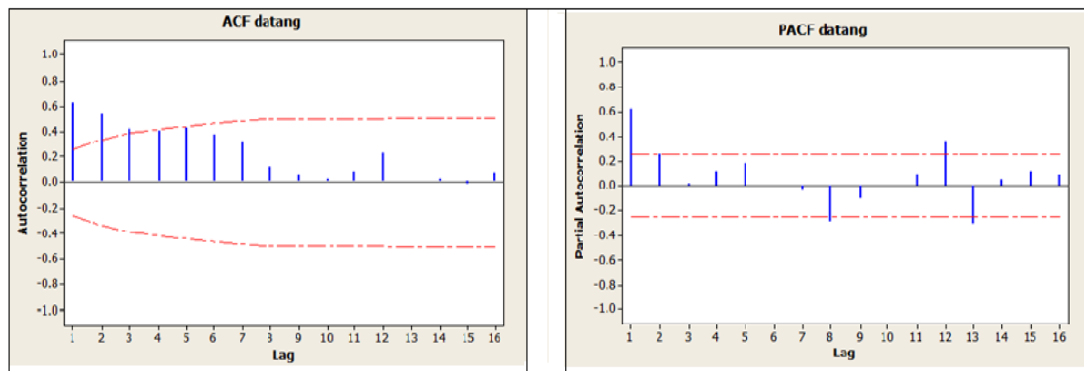
Tahap 1. Identifikasi Model

Tahap identifikasi model yaitu melihat kestasioneran data dan mencari model sementara yang sesuai dengan membuat plot data aktual, grafik autokorelasi dan grafik autokorelasi parsial. Penulis menggunakan bantuan *software* minitab dalam proses analisa agar mempermudah dalam perhitungan, maka diperoleh plot data aktual terhadap waktu pada Gambar 4.2 dan ACF serta PACF pada Gambar 4.3. Berikut merupakan grafik data aktual jumlah penumpang *airlines* yang datang sebanyak 62 data terhitung dari bulan Januari 2005 sampai bulan Februari 2010:




Gambar 4.2 Grafik data aktual jumlah penumpang *airlines* yang datang

Berdasarkan Gambar 4.2 dapat dilihat secara visual (kasat mata) bahwa data tidak stasioner. Grafik menunjukkan bahwa secara umum terjadi kenaikan dengan pola tertentu. Maka dapat disimpulkan bahwa data tidak stasioner. Hal ini dikarenakan adanya unsur tren dan untuk lebih meyakinkan bahwa data tidak stasioner, maka dilakukan uji pasangan ACF dan PACF seperti pada Gambar 4.3.




Gambar 4.3 ACF dan PACF data aktual jumlah penumpang yang datang

Grafik ACF dan PACF pada Gambar 4.3 menunjukkan bahwa data tidak stasioner karena lag-lag pada fungsi autokorelasi tidak turun secara eksponensial dan cenderung mengandung unsur musiman. Adanya unsur musiman pada data dapat dilihat pada pola ACF yang membentuk pola gelombang. Pola gelombang tersebut secara jelas terlihat pada lag ke 7 sampai 12. Maka dapat disimpulkan bahwa data tidak stasioner karena adanya unsur tren dan musiman. Untuk menghilangkan unsur tren dan musiman pada data dapat dilakukan *differencing*. Pertama, untuk menghilangkan unsur tren dilakukan *differencing* non musiman orde satu sehingga diperoleh data hasil *differencing* non musiman orde satu pada Lampiran B. Selanjutnya data hasil *differencing* non musiman juga dapat disajikan dalam bentuk grafik seperti pada Gambar 4.4.



Gambar 4.4 Grafik data hasil *differencing* non musiman

Gambar 4.4 memberikan gambaran bahwa tidak ada lagi unsur tren, hal ini dapat dilihat bahwa grafik pada Gambar 4.4 berfluktuasi sepanjang sumbu horizontal. Tidak adanya unsur tren pada data juga dapat dilihat dengan melakukan uji pasangan ACF dan PACF seperti pada Gambar 4.5. Hal ini dilakukan untuk lebih meyakinkan bahwa data stasioner dari unsur tren.



Gambar 4.5 ACF dan PACF hasil *differencing* non musiman


Tabel 4.2 Nilai ACF dan PACF data hasil *differencing* non musiman

ACF				PACF			
Lag		Lag		Lag		Lag	
1	-0,432963	9	-0,056990	1	-0,432963	9	-0,061203
2	0,052439	10	-0,065479	2	-0,166168	10	-0,143337
3	-0,142986	11	-0,146874	3	-0,238516	11	-0,491897
4	-0,076214	12	0,560609	4	-0,325187	12	0,211289
5	0,125029	13	-0,383558	5	-0,143601	13	-0,134564
6	0,053218	14	0,101976	6	-0,006614	14	-0,150053
7	0,157275	15	-0,175311	7	0,241119	15	-0,117976
8	-0,201912			8	0,062846		

Grafik ACF dan PACF setelah *differencing* non musiman orde satu pada Gambar 4.5 menunjukkan bahwa data sudah stasioner dari unsur tren karena lag-lag pada ACF dan PACF hasil *differencing* non musiman orde satu yang turun secara eksponensial. Sehingga diperoleh model sementara untuk non musiman adalah


MA(1) dengan sekali *differencing*. Hal ini dapat diketahui dari lag-lag pada PACF yang sudah turun secara eksponensial dan ACF *cut off* setelah lag 1. Setelah dilakukan *differencing* non musiman, data sudah stasioner dari unsur tren tetapi belum stasioner dari unsur musiman. Grafik ACF pada Gambar 4.5 mempunyai nilai korelasi tertinggi pada lag 12 yaitu 0,560609. Nilai ACF ini juga dapat dilihat pada Tabel 4.2. Hal ini berarti periode musiman signifikan pada lag 12, sehingga diperoleh $S = 12$.

Selanjutnya untuk menghilangkan unsur musiman pada data, dilakukan *differencing* musiman orde satu sehingga diperoleh data hasil *differencing* musiman orde satu pada Lampiran C. Selanjutnya, data hasil *differencing* musiman orde satu juga dapat disajikan pada Gambar 4.6.



Gambar 4.6 Grafik data setelah *differencing* musiman orde satu

Gambar 4.6 menunjukkan bahwa data sudah stasioner karena data sudah horizontal sepanjang waktu. Namun, untuk lebih meyakinkan dilakukan uji pasangan ACF dan PACF pada Gambar 4.6.



Gambar 4.7 ACF dan PACF data hasil *differencing* musiman orde satu

Gambar 4.7 menunjukkan bahwa data sudah stasioner (tidak ada lagi unsur tren dan musiman). Hal ini dikarenakan oleh lag-lag pada ACF dan PACF turun eksponensial. Pola pasangan ACF dan PACF pada Gambar 4.7 menunjukkan bahwa model musiman yang sesuai adalah MA(1) dengan sekali *differencing* musiman. Hal ini dapat dilihat dari lag-lag pada PACF yang turun secara eksponensial dan ACF *cut off* setelah lag 1. Setelah melakukan *differencing* non musiman dan musiman masing-masing orde satu, maka diperoleh model sementara untuk jumlah penumpang *airlines* yang datang ke Bandara Pekanbaru adalah ARIMA(0,1,1)(0,1,1)¹² dengan model matematisnya sebagai berikut:

$$(1 - B)^1(1 - B^{12})^1 Y_t = \theta_0 + \theta_1(B)\Theta_1(B)^{12} a_t \quad (4.1)$$

atau

$$Y_t = \theta_0 + Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - \theta_1 a_{t-1} - \Theta_1 a_{t-12} + \theta_1 \Theta_1 a_{t-13} \quad (4.2)$$

Tahap 2. Estimasi Parameter Model

Setelah model sementara diperoleh, tahap selanjutnya yaitu mengestimasi parameter dalam model ARIMA(0,1,1)(0,1,1)¹². Estimasi parameter dilakukan dengan metode kuadrat terkecil. Tetapi karena data yang digunakan dalam jumlah yang banyak, maka untuk mempermudah digunakan bantuan *software* Minitab sehingga diperoleh *output* sebagai berikut:

Tabel 4.3 Estimasi parameter model ARIMA(0,1,1)(0,1,1)¹²

Parameter	Koefisien	P
θ_1	0,5619	0,00
Θ_1	0,7113	0,00
θ_0	-22,6	0,874

Tabel 4.3 menunjukkan hasil estimasi parameter pada model ARIMA(0,1,1)(0,1,1)¹² yaitu $\theta_1 = 0,5619$, $\Theta_1 = 0,7113$ dan $\theta_0 = -22,6$. Selanjutnya dilakukan uji signifikansi parameter dalam model yaitu dengan menggunakan nilai *P value*.

a. Uji signifikansi parameter MA(1) yaitu $\theta_1 = 0,5619$

Hipotesis : H_0 : parameter MA(1) tidak signifikan dalam model

H_1 : parameter MA(1) signifikan dalam model

Parameter MA(1) mempunyai nilai *P value* sebesar 0,00, dengan level toleransi 5% berarti $P value < \alpha$ yaitu $0,00 < 0,05$. Sehingga dapat disimpulkan untuk menolak H_0 , yang berarti $\theta_1 = 0,5619$ signifikan dalam model.

b. Uji signifikansi parameter MA(1) musiman yaitu $\Theta_1 = 0,7113$

Hipotesis : H_0 : parameter MA(1) musiman tidak signifikan dalam model

H_1 : parameter MA(1) musiman signifikan dalam model

Parameter MA(1) musiman mempunyai nilai *P value* sebesar 0,00, dengan level toleransi 5% berarti $P value < \alpha$ yaitu $0,00 < 0,05$. Sehingga dapat disimpulkan untuk menolak H_0 , yang berarti $\Theta_1 = 0,7113$ signifikan dalam model.

c. Uji signifikansi konstanta

Hipotesis : H_0 : konstanta tidak signifikan dalam model

H_1 : konstanta signifikan dalam model

Konstanta mempunyai nilai P value sebesar 0,874, dengan level toleransi 5% berarti P value $> \alpha$ yaitu $0,874 > 0,05$. Sehingga dapat disimpulkan untuk menerima H_0 , yang berarti konstanta tidak signifikan dalam model. Konstanta tidak signifikan dalam model sehingga konstanta tidak digunakan dalam model.

Berdasarkan hasil yang diperoleh pada tahap estimasi parameter, maka parameter-parameter hasil estimasi yang signifikan dalam model ARIMA(0,1,1)(0,1,1)¹² adalah $\theta_1 = 0,5619$ dan $\Theta_1 = 0,7113$. Model hasil identifikasi dirumuskan kembali menjadi:

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - 0,5619a_{t-1} - 0,7113a_{t-12} + 0,3997a_{t-13} \quad (4.3)$$

Tahap 3. Verifikasi Model (*Diagnostik Check*)

Tahap *diagnostik check* yaitu melihat apakah model yang dihasilkan sudah layak digunakan untuk peramalan atau belum, dengan melihat residual yang dihasilkan model. Penulis menggunakan dua uji yaitu uji independensi dan kenormalan residual.

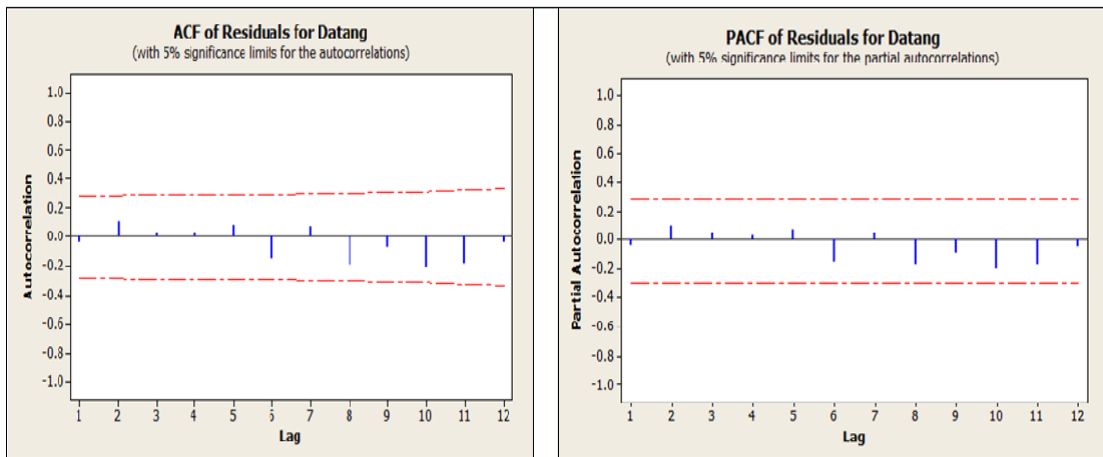
a. Uji independensi residual

Uji ini dilakukan untuk mendeteksi independensi residual antar lag. Model layak digunakan jika residualnya tidak berkorelasi (independen) dan mengikuti proses random. Uji independensi residual dilakukan dengan melihat pasangan ACF dan PACF residual yang dihasilkan model dan membandingkan nilai P -value pada *output* proses *Ljung Box Pierce* dengan level toleransi (α) yang digunakan dalam uji hipotesis:

H_0 : Residual model mengikuti proses random

H_1 : Residual model tidak mengikuti proses random

Kriteria penerimaan H_0 yaitu jika P -value $>$ level toleransi (α). Grafik ACF dan PACF residual model ARIMA(0,1,1)(0,1,1)¹² terlihat pada Gambar 4.8.



Gambar 4.8 ACF dan PACF residual model ARIMA(0,1,1)(0,1,1)¹²

Grafik ACF dan PACF pada Gambar 4.8 menunjukkan bahwa tidak ada lag yang memotong garis batas atas dan batas bawah nilai korelasi residual, sehingga dapat disimpulkan bahwa residual yang dihasilkan model tidak berkorelasi (independen). Selanjutnya, berikut merupakan *output* proses *Ljung Box Pierce* model ARIMA(0,1,1)(0,1,1)¹²:

Tabel 4.4 Output proses *Ljung Box Pierce*


Lag	12	24	36	48
Chi-Square	10,6	24,9	33,5	36,7
DF	9	21	33	45
P value	0,304	0,253	0,443	0,806

Nilai *P Value* setiap lag pada *output Ljung Box Pierce* pada Tabel 4.4 menunjukkan nilai yang lebih besar dari pada level toleransi 5 % yaitu *P Value* > 0,05. Maka dapat ditarik kesimpulan untuk menerima H_0 yang berarti residual model mengikuti proses random.

b. Uji kenormalan residual

Kenormalan residual dapat dilihat pada histogram residual yang dihasilkan model. Jika histogram residual yang dihasilkan model telah mengikuti pola kurva

normal, maka model telah memenuhi asumsi kenormalan. Gambar 4.9 merupakan histogram residual model $ARIMA(0,1,1)(0,1,1)^{12}$ pada data jumlah penumpang *airlines* yang datang.



Gambar 4.9 Histogram residual yang dihasilkan model

Gambar 4.9 menunjukkan histogram residual yang dihasilkan model telah mengikuti pola kurva normal. Sehingga asumsi kenormalan terpenuhi. Berdasarkan uji yang dilakukan pada tahap diagnostik, diperoleh bahwa model sementara $ARIMA(0,1,1)(0,1,1)^{12}$ layak digunakan untuk tahap peramalan. Hal ini disebabkan oleh model $ARIMA(0,1,1)(0,1,1)^{12}$ telah memenuhi syarat uji kelayakan model yaitu residual yang dihasilkan model tidak berkorelasi, telah mengikuti proses random dan memenuhi asumsi kenormalan.

Tahap 4. Penerapan Model untuk Peramalan

Setelah diperoleh model yang layak digunakan untuk peramalan, tahap selanjutnya yaitu menggunakan model untuk peramalan, yang dibedakan untuk data *training*, data *testing* dan peramalan.

a. Data *training*

Data *training* yaitu data yang digunakan untuk membangun model peramalan. Penulis menggunakan data *training* sebanyak 62 data yaitu data dari bulan Januari 2005 sampai bulan Februari 2010. Peramalan dengan menggunakan model ARIMA musiman (0,1,1)(0,1,1)¹² Persamaan 4.3 untuk data *training* adalah sebagai berikut:

$$\begin{aligned}\hat{Y}_{14} &= Y_{13} + Y_2 - Y_1 - 0,5619a_{13} - 0,7113a_2 + 0,3997a_1 \\ &= 75.074 + 58.213 - 60.608 - 0,5619a_{13} - 0,7113a_2 + 0,3997a_1 \\ &= 91.361 \\ &\vdots \\ \hat{Y}_{62} &= Y_{61} + Y_{50} - Y_{49} - 0,5619a_{61} - 0,7113a_{50} + 0,3997a_{49} \\ &= 96.720\end{aligned}$$

Selanjutnya untuk lebih jelas dapat dilihat pada Lampiran D dan pada Gambar 4.10.

b. Data *testing*

Data *testing* digunakan untuk melihat ketepatan hasil peramalan tanpa menggunakan data aktual. Penulis menggunakan data *testing* sebanyak 10 data yaitu dari bulan Maret 2010 sampai bulan Desember 2010. Data yang digunakan yaitu $Y_{t-1} = \hat{Y}_{61}$, $Y_t = \hat{Y}_{62}$. Peramalan dengan menggunakan model ARIMA(0,1,1)(0,1,1)¹² dengan Persamaan 4.3 untuk data *testing* adalah sebagai berikut:

$$\begin{aligned}\hat{Y}_{63} &= \hat{Y}_{62} + \hat{Y}_{51} - \hat{Y}_{50} - 0,5619a_{62} - 0,7113a_{51} + 0,3997a_{50} \\ &= 69.720 + 56.674 - 80.311 - 0,5619a_{62} - 0,7113a_{51} + 0,3997a_{50} \\ &= 85.642 \\ &\vdots \\ \hat{Y}_{72} &= \hat{Y}_{71} + \hat{Y}_{60} - \hat{Y}_{59} - 0,5619a_{71} - 0,7113a_{60} + 0,3997a_{59} \\ &= 94.019\end{aligned}$$

Selanjutnya peramalan untuk data *testing* dapat dilihat pada Tabel 4.5.

Tabel 4.5 Data *testing* dan hasil peramalan penumpang yang datang

No	Bulan	Y_t	Ramalan (\hat{Y}_t)	No	Bulan	Y_t	Ramalan (\hat{Y}_t)
1	Maret 2010	88.014	85.642	6	Agustus 2010	85.951	88.517
2	April 2010	85.160	81.621	7	September 2010	100.650	82.665
3	Mei 2010	90.960	87.425	8	Oktober 2010	101.768	90.310
4	Juni 2010	90.515	89.425	9	November 2010	102.068	87.279
5	Juli 2010	102.467	96.515	10	Desember 2010	118.542	94.019

Hasil peramalan jumlah penumpang yang datang untuk data *testing* pada Tabel 4.5 juga dapat disajikan dalam bentuk grafik seperti pada Gambar 4.10.


c. Peramalan untuk Tahun 2011

Tahap terakhir yang dilakukan adalah meramalkan jumlah penumpang *airlines* yang datang untuk periode selanjutnya yaitu untuk bulan Januari 2011 sampai Desember 2011. Hasil peramalan untuk Tahun 2011, disajikan dalam Tabel 4.6.

Tabel 4.6 Hasil peramalan jumlah penumpang *airlines* yang datang Tahun 2011

No	Bulan (t)	Ramalan (\hat{Y}_t)	No	Bulan (t)	Ramalan (\hat{Y}_t)
1	Januari 2011	93.686	7	Juli 2011	100.381
2	Februari 2011	82.563	8	Agustus 2011	92.360
3	Maret 2011	89.597	9	September 2011	86.485
4	April 2011	85.555	10	Oktober 2011	94.107
5	Mei 2011	91.336	11	November 2011	91.054
6	Juni 2011	93.313	12	Desember 2011	97.772

Hasil peramalan jumlah penumpang yang datang untuk Tahun 2011 pada Tabel 4.6 dapat disajikan dalam bentuk grafik seperti pada Gambar 4.10.



Gambar 4.10 Grafik peramalan *training*, *testing* dan peramalan Tahun 2011


Gambar 4.10 menunjukkan bahwa pola peramalan yang dihasilkan pada data *training* mendekati data aktualnya sedangkan pada data *testing* hasil peramalan kurang mendekati data aktualnya. Hal ini disebabkan oleh data yang digunakan pada data *training* masih menggunakan data aktual sedangkan pada data *testing* tidak menggunakan unsur data aktual tetapi menggunakan data hasil peramalan pada data *training*. Hasil peramalan untuk Tahun 2011 membentuk pola yang sama dengan data aktual jumlah penumpang yang datang pada tahun-tahun sebelumnya yaitu membentuk pola tren musiman.

4.3 Pembentukan Model Peramalan Jumlah Penumpang yang Berangkat

Bagian 4.3 ini berisi tentang tahap-tahap pembentukan model peramalan jumlah penumpang *airlines* yang berangkat dengan metode Box Jenkins. Data yang digunakan untuk pembentukan model tersebut sebanyak 72 data yaitu data perbulan jumlah penumpang *airlines* yang berangkat selama 6 tahun yaitu dari bulan Januari 2005 sampai bulan Desember 2010. Data jumlah penumpang *airlines* yang berangkat disajikan pada Lampiran A dan gambar 4.1. Adapun tahap-tahap pembentukan model yaitu identifikasi model, estimasi parameter, verifikasi model dan peramalan.

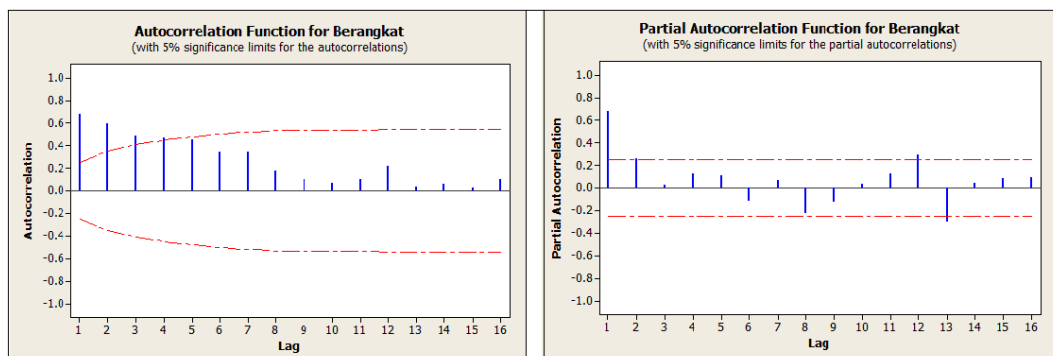
Tahap 1. Identifikasi Model

Tahap ini yaitu melihat kestasioneran data dan mencari model sementara yang sesuai dengan membuat grafik data aktual, grafik autokorelasi dan grafik autokorelasi parsial data aktual. Penulis menggunakan bantuan *software* minitab dalam proses analisa agar mempermudah dalam perhitungan, maka diperoleh grafik data aktual seperti pada Gambar 4.11.




Gambar 4.11 Grafik data aktual jumlah penumpang *airlines* yang berangkat

Berdasarkan Gambar 4.11 dapat dilihat secara visual (kasat mata) bahwa data tidak stasioner. Grafik menunjukkan bahwa secara umum terjadi kenaikan dengan pola tertentu. Maka dapat disimpulkan bahwa data tidak stasioner. Hal ini dikarenakan adanya unsur tren dan untuk lebih meyakinkan bahwa data tidak stasioner, maka dilakukan uji pasangan ACF dan PACF seperti pada Gambar 4.12.




Gambar 4.12 ACF dan PACF data aktual jumlah penumpang yang berangkat

Berdasarkan Gambar 4.12, plot ACF dan PACF mengidentifikasi bahwa data belum stasioner. Hal ini dikarenakan oleh lag-lag pada ACF yang tidak turun secara eksponensial dan cenderung mengandung unsur musiman. Unsur musiman dapat dilihat pada plot ACF yang membentuk pola gelombang yang terlihat jelas pada lag 7 sampai lag 12. Sehingga dapat dikatakan bahwa data tidak stasioner karena adanya unsur tren dan musiman. Metode yang digunakan untuk menghasilkan data yang stasioner yaitu *differencing*. Pertama, untuk menghilangkan unsur tren dilakukan *differencing* non musiman orde pertama. Data hasil *differencing* non musiman orde pertama dapat dilihat pada Lampiran F. Selanjutnya, data hasil *differencing* non musiman orde satu dapat disajikan pada Gambar 4.13:



Gambar 4.13 Data hasil *differencing* non musiman orde 1

Gambar 4.13 memberikan gambaran bahwa tidak ada lagi unsur tren, untuk lebih meyakinkan dilakukan uji pasangan ACF dan PACF seperti pada Gambar 4.14.




Gambar 4.14 ACF dan PACF hasil *differencing* non musiman

Tabel 4.7 Nilai ACF dan PACF hasil *differencing* non musiman berangkat

ACF				PACF			
Lag		Lag		Lag		Lag	
1	-0,421943	9	-0,084095	1	-0,421943	9	-0,109196
2	0,037932	10	-0,061510	2	-0,170451	10	-0,210981
3	-0,127105	11	-0,117496	3	-0,225907	11	-0,407441
4	-0,041582	12	0,496752	4	-0,255986	12	0,224111
5	0,169621	13	-0,365914	5	0,008173	13	-0,109140
6	-0,118270	14	0,098502	6	-0,092997	14	-0,103458
7	0,211372	15	-0,163637	7	0,164731	15	-0,145543
8	-0,151015			8	0,069390		

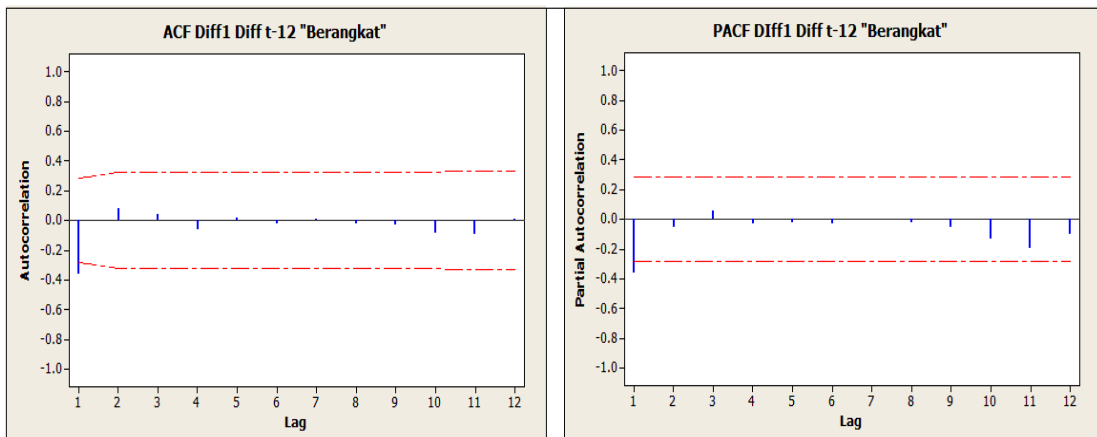
Grafik ACF dan PACF setelah *differencing* non musiman orde satu menunjukkan bahwa data sudah stasioner karena lag-lag pada ACF dan PACF turun secara eksponensial. Sehingga diperoleh model sementara untuk non musiman adalah MA(1) dengan sekali *differencing*. Hal ini dapat diketahui dari lag-lag pada PACF yang turun secara sinusoidal dan ACF *cut off* setelah lag 1. Setelah dilakukan *differencing* non musiman, data sudah stasioner dari unsur tren tetapi tidak stasioner dari unsur tren. Grafik ACF menunjukkan bahwa periode musiman signifikan pada lag 12, sehingga diperoleh $S = 12$. Hal ini dapat diketahui dari Tabel 4.7 pada ACF lag 12 yang mempunyai nilai korelasi tertinggi yaitu 0,496752.

Kedua, untuk menghilangkan unsur musiman, data hasil *differencing* non musiman orde satu dilakukan *differencing* musiman orde satu sehingga diperoleh data hasil *differencing* musiman orde satu seperti disajikan pada Lampiran G. Data hasil *differencing* musiman orde satu juga dapat disajikan pada Gambar 4.15.



Gambar 4.15 Grafik data hasil *differencing* musiman

Gambar 4.15 menunjukkan bahwa data sudah stasioner karena data sudah horizontal sepanjang waktu. Namun, untuk lebih meyakinkan dilakukan ujian pasangan ACF dan PACF seperti pada Gambar 4.16.



Gambar 4.16 ACF dan PACF hasil *differencing* musiman orde satu berangkat

Gambar 4.16 menunjukkan bahwa data sudah stasioner dari unsur tren dan musiman karena lag-lag pada ACF dan PACF data hasil *differencing* musiman turun secara eksponensial. Pola pasangan ACF dan PACF pada Gambar 4.16 mengidentifikasi bahwa model musiman yang sesuai adalah MA(1) dengan sekali *differencing*. Hal ini dapat dilihat dari lag-lag pada PACF yang turun secara eksponensial dan ACF *cut off* setelah lag 1. Setelah melakukan *differencing* non musiman dan musiman masing-masing orde satu, maka diperoleh model yang sementara untuk jumlah penumpang *airlines* yang berangkat dari Bandara Pekanbaru adalah ARIMA(0,1,1)(0,1,1)¹² dengan model matematisnya sebagai berikut:

$$(1 - B)^1(1 - B^{12})^1 Y_t = \theta_0 + \theta_1(B)\Theta_1(B)^{12} a_t \quad (4.4)$$

atau

$$Y_t = \theta_0 + Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - \theta_1 a_{t-1} - \Theta_1 a_{t-12} + \theta_1 \Theta_1 a_{t-13} \quad (4.5)$$

Tahap 2. Estimasi Parameter Dalam Model

Setelah model sementara diperoleh, tahap selanjutnya yaitu mengestimasi parameter dalam model ARIMA(0,1,1)(0,1,1)¹². Estimasi parameter dilakukan dengan metode kuadrat terkecil. Tetapi karena data yang digunakan dalam jumlah yang banyak, maka untuk mempermudah dalam perhitungan digunakan bantuan *software* minitab sehingga diperoleh *output* yang disajikan pada Tabel 4.8.

Tabel 4.8 Estimasi parameter model ARIMA musiman (0,1,1)(0,1,1)¹²

Parameter	Koefisien	P
θ_1	0,5572	0,00
Θ_1	0,7070	0,00
θ_0	-4,4	0,976

Tabel 4.8 menunjukkan hasil estimasi parameter dalam model ARIMA(0,1,1)(0,1,1)¹² yaitu $\theta_1 = 0,5572$, $\Theta_1 = 0,7070$ dan $\theta_0 = -4,4$. Selanjutnya dilakukan uji signifikansi parameter tersebut dengan menggunakan nilai *P value*.

a. Uji signifikansi parameter MA(1) yaitu $\theta_1 = 0,5572$

Hipotesis : H_0 : parameter MA(1) tidak signifikan dalam model

H_1 : parameter MA(1) signifikan dalam model

Parameter MA(1) mempunyai nilai *P value* sebesar 0,00, dengan level toleransi 5% berarti $P \text{ value} < \alpha$ yaitu $0,00 < 0,05$. Sehingga dapat disimpulkan untuk menolak H_0 , yang berarti $\theta_1 = 0,5572$ signifikan dalam model.

b. Uji signifikansi parameter MA(1) musiman yaitu $\Theta_1 = 0,7070$

Hipotesis : H_0 : parameter MA(1) musiman tidak signifikan dalam model

H_1 : parameter MA(1) musiman signifikan dalam model

Parameter MA(1) musiman mempunyai nilai *P value* sebesar 0,00, dengan level toleransi 5% berarti $P \text{ value} < \alpha$ yaitu $0,00 < 0,05$. Sehingga dapat disimpulkan untuk menolak H_0 , yang berarti $\Theta_1 = 0,7070$ signifikan dalam model.

c. Uji signifikansi konstanta

Hipotesis : H_0 : konstanta tidak signifikan dalam model

H_1 : konstanta signifikan dalam model

Konstanta mempunyai nilai *P value* sebesar 0,976, dengan level toleransi 5% berarti $P \text{ value} > \alpha$ yaitu $0,976 > 0,05$. Sehingga dapat disimpulkan untuk menerima H_0 , yang berarti konstanta tidak signifikan dalam model. Konstanta tidak signifikan sehingga konstanta tersebut tidak digunakan dalam model.

Berdasarkan hasil yang diperoleh pada tahap estimasi parameter, maka parameter-parameter hasil estimasi yang signifikan dalam model ARIMA(0,1,1)(0,1,1)¹² adalah $\theta_1 = 0,5572$ dan $\Theta_1 = 0,7070$. Model hasil identifikasi pada Persamaan 4.5 dirumuskan kembali menjadi:

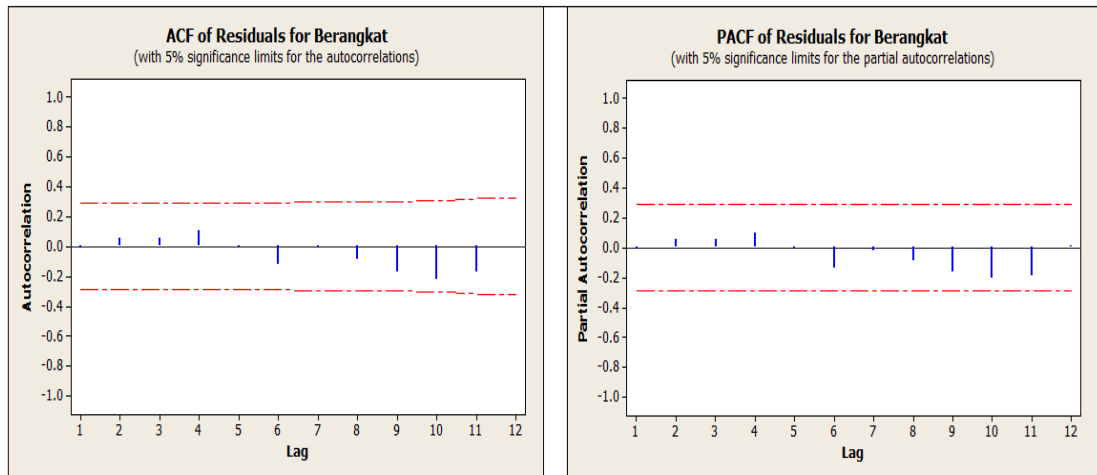
$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - 0,5572a_{t-1} - 0,7070a_{t-12} + 0,394a_{t-13} \quad (4.6)$$

Tahap 3. Verifikasi Model (*Diagnostik Check*)

Tahap *diagnostik check* yaitu melihat apakah model yang dihasilkan sudah layak digunakan untuk peramalan atau belum, dengan melihat residual yang dihasilkan model. Uji yang dilakukan yaitu uji independensi dan kenormalan residual.

a. Uji independensi residual

Uji ini dilakukan untuk mendeteksi independensi residual antar lag. Model dikatakan layak digunakan untuk peramalan jika residual yang dihasilkan tidak berkorelasi (independen). Independensi residual dapat dilihat pada pasangan ACF dan PACF residual yang dihasilkan model pada Gambar 4.17.



Gambar 4.17 ACF dan PACF residual model ARIMA(0,1,1)(0,1,1)¹²

Gambar 4.17 menunjukkan bahwa tidak ada lag yang memotong garis batas atas dan batas bawah nilai korelasi residual, maka dapat disimpulkan bahwa tidak ada korelasi antar lag. Selanjutnya, independensi residual dapat juga dilakukan dengan melihat kerandoman residual yang dihasilkan model yaitu dengan membandingkan nilai *P-value* pada *output* proses *Ljung Box Pierce* dengan selang kepercayaan (α) yang digunakan dalam uji hipotesis:

H_0 : Residual model mengikuti proses random

H_1 : Residual model tidak mengikuti proses random

Kriteria penerimaan H_0 yaitu jika *P-value* > selang kepercayaan.

Berikut merupakan output proses *Ljung Box Pierce* model $ARIMA(0,1,1)(0,1,1)^{12}$:


Tabel 4.9 Output proses *Ljung Box Pierce*

Lag	12	24	36	48
Chi-Square	9,2	20,9	29,4	31,1
DF	9	21	33	45
P value	0,417	0,467	0,648	0,943

Nilai *P Value* setiap lag pada *output Ljung Box Pierce* pada Tabel 4.9 menunjukkan nilai yang lebih besar dari pada selang kepercayaan 5 % yaitu *P Value* > 0,05. Maka dapat ditarik kesimpulan untuk menerima H_0 yang berarti residual model mengikuti proses random.

b. Uji kenormalan residual

Kenormalan residual dapat dilihat pada histogram residual yang dihasilkan model. Jika histogram residual yang dihasilkan model telah mengikuti pola kurva normal, maka model telah memenuhi asumsi kenormalan. Berikut merupakan histogram residual model $ARIMA(0,1,1)(0,1,1)^{12}$ data jumlah penumpang *airlines* yang berangkat:



Gambar 4.18 Histogram residual model $ARIMA(0,1,1)(0,1,1)^{12}$

Gambar 4.18 menunjukkan histogram residual yang dihasilkan model telah terdistribusi secara normal. Hal ini telah memenuhi asumsi kenormalan. Berdasarkan uji yang dilakukan pada tahap diagnostik, diperoleh bahwa model sementara ARIMA(0,1,1)(0,1,1)¹² layak digunakan untuk tahap peramalan. Hal ini disebabkan oleh model ARIMA(0,1,1)(0,1,1)¹² telah memenuhi syarat uji kelayakan model yaitu residual yang dihasilkan tidak berkorelasi, telah mengikuti proses random dan memenuhi asumsi kenormalan.

Tahap 4. Penerapan Model untuk Peramalan

Setelah diperoleh model yang layak digunakan untuk peramalan, tahap selanjutnya yaitu menggunakan model untuk peramalan, yang dibedakan untuk data *training*, *testing* dan peramalan.

a. Data *training*

Data *training* yaitu data yang digunakan untuk membangun model peramalan. Penulis menggunakan data *training* sebanyak 62 data yaitu data dari bulan Januari 2005 sampai bulan Februari 2010. Peramalan dengan menggunakan model ARIMA(0,1,1)(0,1,1)¹² Persamaan 4.6 untuk data *training* adalah sebagai berikut:

$$\begin{aligned}\hat{Y}_{14} &= Y_{13} + Y_2 - Y_1 - 0,5619a_{13} - 0,7113a_2 + 0,3997a_1 \\ \hat{Y}_{14} &= 71.464 + 57.331 - 62.590 - 0,5619a_{13} - 0,7113a_2 + 0,3997a_1 \\ &= 64.557 \\ &\cdot \\ &\cdot \\ \hat{Y}_{62} &= Y_{61} + Y_{50} - Y_{49} - 0,5619a_{61} - 0,7113a_{50} + 0,3997a_{49} \\ &= 81.723\end{aligned}$$

Selanjutnya untuk lebih jelas dapat dilihat pada Lampiran H dan Gambar 4.19.

b. Data *testing*

Data *testing* digunakan untuk melihat ketepatan hasil peramalan tanpa menggunakan data aktual. Penulis menggunakan data *testing* sebanyak 10 data yaitu

dari bulan Maret 2010 sampai bulan Desember 2010. Data yang digunakan adalah $Y_{t-1} = \hat{Y}_{61}$, $Y_t = \hat{Y}_{62}$. Peramalan dengan menggunakan model ARIMA(0,1,1)(0,1,1)¹²

Persamaan 4.6 untuk data *testing* adalah sebagai berikut:

$$\begin{aligned}\hat{Y}_{63} &= \hat{Y}_{62} + \hat{Y}_{51} - \hat{Y}_{50} - 0,5619a_{62} - 0,7113a_{51} + 0,3997a_{50} \\ \hat{Y}_{63} &= 81.723 + 75.955 - 65.124 - 0,5619a_{62} - 0,7113a_{51} + 0,3997a_{50} \\ &= 85.216 \\ &\vdots \\ \hat{Y}_{72} &= \hat{Y}_{71} + \hat{Y}_{60} - \hat{Y}_{59} - 0,5619a_{71} - 0,7113a_{60} + 0,3997a_{59} \\ &= 94.773\end{aligned}$$

Selanjutnya, untuk lebih jelas hasil peramalan disajikan pada Tabel 4.10.

Tabel 4.10 Data *testing* dan hasil peramalan penumpang yang berangkat

No	Bulan (<i>t</i>)	Y_t	Ramalan (\hat{Y})	No	Bulan (<i>t</i>)	Y_t	Ramalan (\hat{Y})
1	Maret 2010	89.265	85.216	6	Agustus 2010	85.450	90.030
2	April 2010	86.231	82.388	7	September 2010	102.133	83.870
3	Mei 2010	90.687	87.420	8	Oktober 2010	104.983	91.518
4	Juni 2010	92.288	90.354	9	November 2010	100.833	86.765
5	Juli 2010	100.836	93.940	10	Desember 2010	100.670	94.773

Hasil peramalan data *testing* pada Tabel 4.10 dapat juga disajikan dalam bentuk grafik seperti pada Gambar 4.19.


c. Peramalan untuk Tahun 2011

Tahap terakhir yang dilakukan adalah meramalkan jumlah penumpang *airlines* yang berangkat untuk periode selanjutnya yaitu untuk bulan Januari 2011 sampai Desember 2011. Hasil peramalan untuk Tahun 2011, disajikan dalam Tabel 4.11.

Tabel 4.11 Hasil peramalan jumlah penumpang yang berangkat Tahun 2011

No	Bulan (t)	Ramalan (\hat{Y})	No	Bulan (t)	Ramalan (\hat{Y})
1	Januari 2011	90.449	7	Juli 2011	98.077
2	Februari 2011	83.393	8	Agustus 2011	94.162
3	Maret 2011	89.370	9	September 2011	87.997
4	April 2011	86.538	10	Oktober 2011	95.641
5	Mei 2011	91.565	11	November 2011	90.884
6	Juni 2011	94.495	12	Desember 2011	98.887

Hasil peramalan pada tahap *training*, *testing* dan peramalan Tahun 2011 jumlah penumpang *airlines* yang berangkat dapat disajikan pada Gambar 4.19.



Gambar 4.19 Peramalan *training*, *testing* dan peramalan Tahun 2011

Gambar 4.19 menunjukkan bahwa peramalan yang dihasilkan pada data *training* mendekati data aktualnya sedangkan pada *testing* kurang mendekati data aktualnya. Hal ini disebabkan oleh data yang digunakan pada data *training* masih menggunakan data aktual sedangkan pada *testing* tidak menggunakan data aktual tetapi menggunakan data hasil peramalan pada data *training*. Hasil peramalan pada Tahun 2011 mempunyai pola yang sama dengan data aktual jumlah penumpang *airlines* yang berangkat pada tahun-tahun sebelumnya.

Secara umum dapat disimpulkan bahwa peramalan pada data *training* memberikan nilai ramalan yang mendekati nilai aktual. Namun, peramalan pada data *testing* memberikan nilai ramalan yang kurang mendekati nilai aktual. Hal ini dikarenakan oleh peramalan yang dilakukan pada data *training* menggunakan unsur data aktual sedangkan pada *testing* tidak menggunakan unsur data aktual tetapi menggunakan data hasil peramalan pada data *training*.

Setelah melakukan tahap-tahap peramalan menggunakan metode Box Jenkins, diperoleh bahwa nilai ramalan yang dihasilkan mengikuti pola data aktual dalam kasus ini mengikuti pola tren musiman. Hasil peramalan menunjukkan bahwa jumlah penumpang *airlines* yang datang dan berangkat tertinggi terjadi pada akhir tahun yaitu di bulan Desember. Pola hasil ramalan yang dihasilkan sama dengan pola data aktual sebelumnya, yaitu mempunyai nilai tertinggi di setiap akhir tahun. Hal ini sesuai dengan model yang dihasilkan dalam penelitian ini yaitu $ARIMA(0,1,1)(0,1,1)^{12}$, yang berarti terjadi kenaikan jumlah penumpang *airlines* dengan periode musiman $S = 12$ yaitu bulan Desember. Tingginya jumlah penumpang *airlines* pada akhir tahun disebabkan oleh banyaknya masyarakat Pekanbaru yang memanfaatkan liburan natal dan akhir tahun dengan bepergian ke luar daerah menggunakan transportasi udara.

BAB V

PENUTUP

Bab V dalam penelitian ini terdiri dari kesimpulan dari pembahasan yang telah dilakukan pada Bab IV dan saran bagi pembaca yang ingin melanjutkan penelitian ini.

5.1 Kesimpulan

Berdasarkan pembahasan yang dilakukan pada Bab IV yaitu analisa dan tahap-tahap pembentukan model peramalan, maka dapat disimpulkan sebagai berikut:

- a. Model yang sesuai untuk jumlah penumpang *airlines* PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru dengan menggunakan tahap-tahap metode Box Jenkins yaitu:

1. Jumlah penumpang yang datang adalah $ARIMA(0,1,1)(0,1,1)^{12}$ dengan model:

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - 0,5619a_{t-1} - 0,7113a_{t-12} + 0,3997a_{t-13}$$

2. Jumlah penumpang yang berangkat adalah $ARIMA(0,1,1)(0,1,1)^{12}$ dengan model:

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + a_t - 0,5572a_{t-1} - 0,7070a_{t-12} + 0,394a_{t-13}$$

- b. Secara umum, hasil peramalan pada data *training* mendekati data aktual sedangkan pada data *testing* kurang mendekati data aktual. Hal ini disebabkan oleh data yang digunakan pada *training* masih terdapat unsur data aktual sedangkan pada *testing* tidak menggunakan data aktual tetapi menggunakan data hasil peramalan pada *training*. Walaupun demikian, hasil peramalan secara keseluruhan mempunyai pola yang sama dengan pola data aktual tahun-tahun sebelumnya yaitu pola tren musiman.

5.2 Saran

Tugas akhir ini menjelaskan peramalan jumlah penumpang *airlines* yang datang dan berangkat semua perusahaan penerbangan yang dikelola oleh PT. Angkasa Pura II Bandara Sultan Syarif Kasim II Pekanbaru dengan menggunakan metode runtun waktu (Box Jenkins). Bagi para pembaca penulis menyarankan untuk meramalkan jumlah penumpang *airlines* untuk masing-masing perusahaan penerbangan yang ada di kota Pekanbaru.

DAFTAR PUSTAKA

- Cryer, Jonathan D. *Time Series Analysis*. PWS-KENT Publishing Company. Boston. 1986.
- Dani, K. *Kamus Lengkap Bahasa Indonesia*. Penerbit-Putra Harsa. Surabaya. 2002.
- Damardjati, R. S. *Istilah-Istilah Dunia Pariwisata*. 2001. [online]
<http://hubud.dephub.go.id/?id+statistik+detail+angud>
- Delurgio, Stephen A. *Forecasting Principles and Applications*. Kansas. 1998.
- Efendi, Riswan. *Analisa Runtun Waktu*. Matematika Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau. 2010.
- Fatmawati, Ika Kurnia. "Prakiraan Curah Hujan Bulanan Kecamatan Baturaden Kabupaten Banyumas dengan Model ARIMA di Stasiun Klimatologi Semarang". *Tugas Akhir Mahasiswa UNNES*. 2007.
- Firdaus, M. *Analisis Deret Waktu Satu Ragam*. IPB Press. 2006.
- Hanke, John E, dan Dean W. Wichern. *Business Forecasting*. Pearson Education International, USA. 2009.
- Istiqomah. "Aplikasi Model ARIMA untuk *Forecasting* Produksi Gula pada PT. Perkebunan Nusantara IX (Persero)". *Tugas Akhir Mahasiswa UNNES*. 2006.
- Jumroh. "Estimasi Maksimum Likelihood pada Model ARIMA (1,1,0) Box Jenkins". *Tugas Akhir Mahasiswa UNNES*. 2005.
- Lumbantobing, Magdalena. "Peramalan Nilai Penjualan Energi Listrik Di PT. PLN (Persero) Cabang Binjai untuk Tahun 2008". *Tugas Akhir Mahasiswa Universitas Sumatra Utara*. 2008.
- Makridarkis. Spyros dkk. *Metode dan Aplikasi Peramalan*. Edisi ke-2. Penerbit-Erlangga. 1999.
- Mardaningsih, Wira. "Prosedur Pelaporan Hasil Penjualan Kupon Pelayanan Penumpang Pesawat Udara (PJP2U) PT. Angkasa Pura I (Persero) di Bandar Udara Adi Soemarno Surakarta". *Tugas Akhir Mahasiswa Universitas Sebelas Maret*. Surakarta. 2010.

- Milasari, Ika. "Peramalan Jumlah Penderita Demam Berdarah Menggunakan Model ARIMA Musiman". *Tugas Akhir Mahasiswa Universitas Islam Negeri Malang*. Malang. 2008.
- Montgomery, Douglas C dkk. *Intoduction to Time Series Analysis and Forecasting*. United State of America. Wiley Interscience. 2008.
- Nurhayati, Astin. "Peramalan Jumlah Penumpang pada PT Angkasa Pura I (Persero) Kantor Cabang Bandar Udara Internasional Adi Sutjipto Yogyakarta dengan Metode *Winter's Exponential Smoothing* dan *Seasonal ARIMA*". Yogyakarta. 2009.
- Prasetyo, Dedy Dwi. *Peramalan Menggunakan Metode Pemulusan*. 2009.
- Poerwadarminta, WJS. *Kamus Umum Bahasa Indonesia*. 1991.
- Rozana, Lya Amalia. "Analisa Model Runtun Waktu dan Estimasi Parameter Data Produksi Gula PTP. Nusantara IX (Persero) Jatibarang Kabupaten Brebes Dengan Program Minitab". *Tugas Akhir Mahasiswa UNNES*. 2007.
- Santoso, Singgih. *Bussiness Forecasting*. Jakarta. PT. Elex Media Komputindo. 2009.
- Sembiring, R.K. *Analisis Regresi*. Edisi kedua. Penerbit ITB. 1995.
- Tarigan, S Peronika. "Proyeksi Jumlah Penumpang Domestik pada PT. Angkasa Pura II Bandara Polonia Medan 2010-2011". *Tugas Akhir Mahasiswa USU*. Medan. 2009.
- Widodo, Wahyu. "Metode Auturegresi dan Autokorelasi untuk Meramalkan Jumlah Penjualan Pakaian di Toko Yuanita Purwodadi". *Tugas Akhir Mahasiswa UNNES*. Semarang. 2005.
- Wei, William W.S. *Time Series Analysis*. California. Wesley Publishing Company, Inc. 1989.